METODA ZA ODABIR OPTIMALNIH RAZINA KVALITETE U POSTUPKU KODIRANJA I SEGMENTACIJE VIDEOSIGNALA ZA PRILAGODLJIVO VIDEOSTRUJANJE

Vlaović, Jelena

Doctoral thesis / Disertacija

2022

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

Permanent link / Trajna poveznica: https://urn.nsk.hr/urn:nbn:hr:200:069525

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA

Jelena Vlaović

METODA ZA ODABIR OPTIMALNIH RAZINA KVALITETE U POSTUPKU KODIRANJA I SEGMENTACIJE VIDEOSIGNALA ZA PRILAGODLJIVO VIDEOSTRUJANJE

Doktorski rad

Osijek, 2021.

Doktorski rad je izrađen na Zavodu za komunikacije, Fakultet elektrotehnike, računarstva i informacijskih tehnologija, Sveučilište Josipa Jurja Strossmayera u Osijeku.

Mentor: prof.dr.sc. Snježana Rimac-Drlje

Sumentor: prof.dr.sc. Drago Žagar

Doktorski rad ima 193 stranice.

Doktorski rad broj: 83

Naslov doktorskog rada

- (HRV) Metoda za odabir optimalnih razina kvalitete u postupku kodiranja i segmentacije videosignala za prilagodljivo videostrujanje
- (ENG) Method for selecting optimal quality levels in the process of video encoding and segmentation for adaptive video streaming

Izvorni znanstveni doprinosi

1. Okvir za analizu i optimizaciju parametara algoritama za videostrujanje prilagodljivo mrežnim uvjetima zasnovano na MPEG DASH normi
2. Metoda za odabir optimalnih razina kvalitete u postupku kodiranja i segmentacije videosignala za prilagodljivo videostrujanje zasnovana na prostorno-vremenskim značajkama videosadržaja
3. Baza kodiranih i segmentiranih videosignala sa skupom parametara za prilagodljivo videostrujanje zasnovano na MPEG DASH normi
4. Vrednovanje metode za odabir optimalnih razina kvalitete videosignala za prilagodljivo videostrujanje

Povjerenstvo za ocjenu doktorske disertacije

- Izv. prof. dr. sc. Mario Vranješ, predsjednik, Sveučilište J. J. Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek;
- Prof. dr. sc. Drago Žagar, član, Sveučilište J. J. Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek;
- Prof. dr. sc. Snježana Rimac-Drlje, mentor, Sveučilište J. J. Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek;
- Prof. dr. sc. Sonja Grgić, član, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva;
- Izv. prof. dr. sc. Krešimir Grgić, član, Sveučilište J. J. Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek;

Povjerenstvo za obranu doktorske disertacije

- Izv. prof. dr. sc. Mario Vranješ, predsjednik, Sveučilište J. J. Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek;
- Prof. dr. sc. Drago Žagar, član, Sveučilište J. J. Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek;
- Prof. dr. sc. Snježana Rimac-Drlje, mentor, Sveučilište J. J. Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek;
- Prof. dr. sc. Sonja Grgić, član, Sveučilište u Zagrebu, Fakultet elektrotehnike i računarstva;
- Izv. prof. dr. sc. Krešimir Grgić, član, Sveučilište J. J. Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek;

Datum obrane doktorske disertacije: 6. listopad 2021.

Zahvaljujem se mentorici prof. dr. sc. Snježani Rimac-Drlje i sumentoru sumentoru prof. dr. sc. Dragi Žagaru koji su me savjetovali kroz cijelo trajanje poslijediplomskog doktorskog studija, poticali na objavljivanje znanstvenih radova te svojim znanjem i iskustvom uvijek je bili spremni pomoći.

Hvala i mojim roditeljima Đurđici i Bruni te bratu Niki na bezgraničnoj podršci i vjeri u mene tijekom cijelog mog školovanja.

Zahvaljujem se i mom suprugu Krešimiru na razumijevanju za sve moje duge ostanke na poslu i motivaciji koju mi je pružio kada mi je zatrebala. Moja radost potpuna je tek kada ju mogu podijeliti s vama.

SADRŽAJ

1. Uvod 1

2. Prilagodljivo videostrujanje 5

2.1.MPEG DASH norma 6

2.1.1.Sustav za prilagodljivo videostrujanje zasnovan na MPEG DASH normi 7

2.1.2.Algoritmi za prilagodbu prijenosne brzine kod prilagodljivog videostrujanja 11

2.1.2.1. Algoritmi zasnovani na dostupnoj propusnosti 11

2.1.2.2. Algoritmi zasnovani na popunjenosti međuspremnika i dostupnoj propusnosti . 14

2.1.2.3. Hibridni ABR algoritmi 15

2.2.Parametri kvalitete korisničkog iskustva u prilagodljivom videostrujanju 20

2.2.1.Usporedba ABR algoritama za prilagodljivo videostrujanje 23

3. Kvaliteta videosignala 33

3.1.Prostorna i vremenska informacija videosadržaja 34

3.2.Metode za ocjenu kvalitete videosignala 43

3.2.1.Subjektivne metode za ocjenu kvalitete videosignala 43

3.2.2.Objektivne metode za ocjenu kvalitete videosignala 45

3.2.2.1.Dostupna istraživanja 49

3.2.2.2.Usporedba objektivnih metoda za ocjenu kvalitete videosignala 50

4. Metoda za odabir optimalnih razina kvalitete u postupku kodiranja i segmentacije videosignala 62

4.1.Odabir optimalnih mjesta promjene prostorne rezolucije 62

4.1.1.Dostupna istraživanja 62

4.1.2.Razvoj postupka za odabir optimalnih kodnih brzina za promjenu prostorne rezolucije 64

4.1.2.1.Točke promjene prostorne rezolucija u ovisnosti o SSIM-u 67

4.1.2.2.Funkcijska ovisnost prijenosne brzine o prostornoj rezoluciji i SITI-ju 69

4.1.2.3.Ugrožđavanje točaka promjene prostorne rezolucije 73

4.1.3.Vrednovanje predložene metode 77
4.1.3.1.Statistička analiza 78
4.1.3.2.Vrednovanje metode pomoću subjektivne ocjene kvalitete videosignala 80
4.1.3.3.Vrednovanje metode pomoću algoritama za prilagodljivo videostrujanje 81
4.2.Metoda za odabir broja i parametara reprezentacija 85
4.2.1.Dostupna istraživanja 85
4.2.2.Razvoj metode za odabir broja i parametara reprezentacija 86
4.2.3.Optimalni skup reprezentacija 93
4.3.Vrednovanje metode za odabir optimalnih razina kvalitete u postupku kodiranja i segmentacije videosignala za prilagodljivo videostrujanje 96
4.3.1.Vrednovanje metode pomoću algoritama za prilagodljivo videostrujanje 96
4.3.2.Ocjena rezultata pomoću subjektivne metode za ocjenu kvalitete videosignala 98
5. Baza kodiranih i segmentiranih videosignala sa skupom parametara za prilagodljivo videostrujanje zasnovano na MPEG DASH normi 100
5.1.Analiza dostupnih baza za ispitivanje sustava za prilagodljivo videostrujanje 100
5.2.Opis predložene baze kodiranih i segmentiranih videosignala 103
6. Okvir za analizu i optimizaciju parametara algoritama za videostrujanje prilagodljivo mrežnim uvjetima zasnovano na MPEG DASH normi 110
6.1.Dostupna rješenja 111
6.2.Opis okvira za analizu i optimizaciju parametara algoritama za videostrujanje prilagodljivo mrežnim uvjetima zasnovano na MPEG DASH normi 112
6.3.Umjetno generiranje ispitnih zapisa 116
6.3.1.Analiza 3G i 4G baze ispitnih zapisa pomoću Nakagami raspodjele 117
6.4.Rezultati mjerenja utjecaja parametara mreže i reprezentacija videosignala na SSIM 133
7. Zaključak 149
Literatura 155
Sažetak 166

Abstract 168
Životopis 170
Prilozi 171

1. UVOD

Nagli porast dostupnosti širokopojasne internetske veze tijekom posljednjeg desetljeća rezultirao je velikom potražnjom za različitim multimedijskim sadržajima. Posljednjih je godina prijenos digitalnih videosignala postao dio svakodnevnog života zbog stalne dostupnosti internetske veze i raznovrsnih aplikacija koje omogućuju dohvaćanje željenih videosignala na zahtjev (engl. *Video on Demand* - VoD). U usporedbi s ostalim sadržajima koji se dostavljaju korisnicima putem Interneta, videosignali su i dalje najsloženiji u smislu prilagodbe promjenjivim mrežnim uvjetima i osiguranja najbolje moguće kvalitete korisničkog iskustva (engl. *Quality of Experience* - QoE).

Predviđa se da će se internetski videopromet povećati s 105 EB mjesečno koliko je bilo 2020. godine na 240 EB mjesečno do 2022. godine, a VoD promet će se gotovo udvostručiti do 2022. godine [1]. S obzirom na stalni porast internetskog videoprometa, bilo je potrebno razviti tehnologiju koja će omogućiti učinkovitije korištenje dostupnih resursa uz osiguranje jednake ili bolje kvalitete korisničkog iskustva. Kako bi se riješili postojeći problemi vezani uz prilagodbu razina kvalitete uvjetima u mreži, razvijene su različite VoD aplikacije i algoritmi za prilagodbu prijenosne brzine (engl. *Adaptive Bitrate* - ABR). U istraživanjima dostupnim u literaturi predstavljeni su ABR algoritmi koji uzimaju u obzir različite parametre kako bi se prilagodili promjenjivim mrežnim uvjetima kao što su popunjenost međuspremnika, veličina videosegementa, procijenjena dostupna propusnost i sl.

Sustavi koji koriste algoritme za prilagodbu prijenosne brzine razvijaju se ubrzano posljednjih deset godina te tako postoje različita više ili manje učinkovita rješenja. Iz dostupnih istraživanja može se zaključiti da je većina istraživanja usmjerena na korisničku stranu sustava za prilagodljivo videostrujanje na kojoj se i nalazi algoritam za prilagodbu prijenosne brzine, no poslužiteljska strana još uvijek nije dovoljno istražena, posebno se to odnosi na postupak kodiranja i segmentacije videosignala. Prva rješenja koja su se odnosila na pripremu videosignala za strujanje (engl. *streaming*) temeljila su se na unaprijed određenim i jedinstvenim parametrima kodiranja i parametrima skupa reprezentacija, no ubrzo se pokazalo da nije optimalno koristiti iste parametre za videosignale različite kompleksnosti, odnosno s različitim razinama prostorne i vremenske aktivnosti. Daljnjim razvojem aplikacija pružatelja usluga VoD, svaki je od pružatelja usluga također predložio svoj set parametara za kodiranje i segmentaciju videosignala koji su se u početku koristili u ispitivanjima algoritama za prilagodljivo videostrujanje [2, 3]. Nakon sustava koji su koristili videosignale kodirane i segmentirane na isti način neovisno o sadržaju, predloženi su

skupovi reprezentacija s različitim parametrima za svaki žanr sadržaja (sport, crtani film i dokumentarni film) što, iako je predstavljalo napredak, i dalje nije riješilo problem različite prostorne i vremenske aktivnosti sadržaja unutar određenog žanra [4]. Značajniji napredak u procesu odabira parametara kodiranja i segmentacije predstavila su rješenja koja uzimaju u obzir sadržaj videosignala i to na način da se parametri za segmentaciju videosignala odabiru uz pomoć probnog kodiranja izvornog videosignala [5, 6]. Uzimajući u obzir da je većina dostupnih rješenja zaštićena autorskim pravima, zahtijeva veliku računalnu snagu ili ne uzima u obzir prostornu i vremensku aktivnost videosadržaja, postoji prostor za poboljšanje u pogledu odabira optimalnih skupova parametara za kodiranje i segmentaciju videosignala. Prvi dio istraživanja predstavljen u ovom doktorskom usmjeren je na odabir parametara za kodiranje i segmentaciju videosignala uz pomoć metode koja u obzir uzima prostornu i vremensku aktivnost videosadržaja, a ne zahtjeva probno kodiranje svakog pojedinog videosignala.

Daljnjim istraživanjem se pokazalo da ne postoje odgovarajuće baze videosignala pripremljene za videostrujanje koje sadrže raznovrstan sadržaj u smislu prostorne i vremenske aktivnosti uz sve potrebne datoteke koje se trebaju nalaziti na poslužitelju. Također, za videosignale u dostupnim bazama ili nema informacija na koji način su odabrani parametri za kodiranje i segmentaciju ili su korištene preporuke pružatelja usluga VoD. S obzirom na nedostatak baza videosignala pripremljenih za videostrujanje koje sadrže raznovrstan sadržaj, u ovom doktorskom radu predstavljena je nova baza čiji su videosignali odabrani uzimajući u obzir prostornu i vremensku informaciju videosadržaja.

Osim parametara za kodiranje i segmentaciju videosignala istraživanje u ovom doktorskom radu usmjereno je i na razvoj okvira koji omogućuje sustavno ispitivanje parametara koji utječu na kvalitetu korisničkog iskustva kao što su početno kašnjenje, broj i dubina prebacivanja razina kvalitete i zastoji u reprodukciji videosignala. U dostupnoj literaturi postoje rješenja koja u obzir uzimaju promjene u dostupnoj propusnosti, ali komuniciraju izravno s poslužiteljem što znači da je za svaku promjenu u načinu kodiranja i segmentacije potrebno pripremati novi sadržaj koji je potrebno pohraniti na poslužitelj. Također ne postoji dovoljan broj baza s mrežnim ispitnim zapisima koji bi se mogli koristiti za sustavno ispitivanje algoritama za prilagodljivo videostrujanje. Ispitivanja algoritama za prilagodljivo videostrujanje u literaturi izvršena su ili pomoću umjetno generiranih mrežnih ispitnih zapisa koji ne opisuju stvarne uvjete u mreži ili pomoću dvije dostupne baze mrežnih ispitnih zapisa snimljenih za 3G i 4G mobilne mreže. Kako bi se riješili problemi nedovoljnog broja mrežnih ispitnih zapisa i manjak okvira koji se može koristiti za analizu parametara kodiranja i segmentacije, u ovom doktorskom radu predložen je

okvir koji ima mogućnost računalnog generiranja mrežnih ispitnih zapisa na temelju teorijskog modela zasnovanog na izmjerenim mrežnim ispitnim zapisima. Nadalje, okvir pruža mogućnost sustavne analize utjecaja parametara mreže kao i parametara kodiranja i segmentacije videosignala na kvalitetu videosignala u sustavima zasnovanim na prilagodljivom videostrujanju.

Doktorski rad koji je rezultat istraživanja parametara kodiranja i segmentacije videosignala organiziran je kako slijedi. U drugom poglavlju dan je opis razvoja sustava za prilagodljivo videostrujanje čime je istaknuta potreba za normizacijom. Također opisan je nastanak MPEG (engl. *Moving Picture Experts Group)* norme za promjenjivo prilagodljivo strujanje putem HTTP-a (engl. *Hypertext Transfer Protocol*), nazvane MPEG DASH (engl. *MPEG Dynamic Adaptive Streaming over HTTP*) te je dan opis sustava za prilagodljivo videostrujanje zasnovano na MPEG DASH normi s naglaskom na algoritme za prilagodbu prijenosne brzine. Nadalje, drugo poglavlje opisuje parametre kvalitete korisničkog iskustva kod prilagodljivog videostrujanja te rezultate usporedbe ovih parametara kod primjene različitih algoritama za prilagodbu prijenosne brzine pri različitim mrežnim uvjetima.

Treće poglavlje doktorskog rada daje teorijsku osnovu vezano uz objektivne i subjektivne metode za ocjenu kvalitete videosignala te prostorne i vremenske informacije videosadržaja. Predstavljeno je istraživanje vezano uz utjecaj prostorne i vremenske informacije videosadržaja na kodiranje te su dani rezultati usporedbe objektivnih metoda za ocjenu kvalitete videosignala za odabrane parametre kodiranja i skup videosignala.

U četvrtom poglavlju predstavljena je nova metoda za odabir optimalnih razina kvalitete u postupku kodiranja i segmentacije videosignala za prilagodljivo videostrujanje koja koristi informaciju o prostornoj i vremenskoj aktivnosti videosadržaja. Nakon pregleda relevantnih istraživanja, opisan je razvoj prvog dijela metode koji omogućava odabir optimalnih mjesta promjene prostorne rezolucije u ovisnosti o aktivnosti videosadržaja, zasnovanog na objektivnoj ocjeni kvalitete videosignala koja je pokazala najbolju korelaciju sa subjektivnim ispitivanjem. Predstavljeni su i rezultati vrednovanja predloženog postupka uz pomoć statističke analize, algoritama za prilagodljivo videostrujanje i subjektivne ocjene kvalitete videosignala. Nadalje, opisan je razvoj drugog dijela metode koji omogućava optimalan odabir broja i parametara reprezentacija za dani videosadržaj pri čemu se koristi model ovisnosti srednje vrijednosti subjektivne ocjene (engl. *Mean Opinion Score* - MOS) o objektivnoj ocjeni kvalitete videosignal opisan u [7]. Na kraju ovog pogavlja prikazani su rezultati vrednovanja nove metode za odabir optimalnih razina kvalitete u postupku kodiranja i segmentacije videosignala za prilagodljivo

videostrujanje dobiveni primjenom algoritama za prilagodljivo videostrujanje te provedbom subjektivnog ocjenjivanja kvalitete videosignala.

Peto poglavlje daje pregled dostupnih baza s videosignalima pripremljene za videostrujanje te pregled nove baze videosignala pripremljene za videostrujanje koja sadrži raznovrstan sadržaj u smislu prostorne i vremenske aktivnosti uz sve potrebne datoteke koje se trebaju nalaziti na poslužitelju. Parametri za kodiranje i segmentaciju videosignala koji se nalaze u predloženoj bazi odabrani su koristeći metodu opisanu u četvrtom poglavlju.

U šestom poglavlju je predložen okvir za analizu i optimizaciju parametara algoritama za videostrujanje prilagodljivo mrežnim uvjetima zasnovano na MPEG DASH normi. Predloženi okvir nadopunjen je modulom koji ima mogućnost računalnog generiranja mrežnih ispitnih zapisa zasnovanih na izmjerenim mrežnim ispitnim zapisima kako bi se riješio problem nedovoljnog broja mrežnih ispitnih zapisa u dostupnim bazama koji se mogu koristiti u ispitivanju algoritama za prilagodljivo videostrujanje. Parametri za računalno generiranje mrežnih ispitnih zapisa određeni su analizom dostupnih baza s mrežnim ispitnim zapisima snimljenim za 3G i 4G mobilne mreže. Primjenom predloženog okvira provedeno je mjerenje utjecaja parametara mreže i parametara kodiranja i segmentacije na kvalitetu videosignala te je dana analiza dobivenih rezultata.

U sedmom poglavlju su dana zaključna razmatranja o rezultatima istraživanja provedenih u sklopu ovog doktorskog rada, znanstveni doprinosi te su predložene smjernice za daljnji istraživački rad vezan uz MPEG DASH normu.

2. PRILAGODLJIVO VIDEOSTRUJANJE

Razvojem Interneta, kao i sklopovlja koje podržava nove internetske tehnologije, razvila se povećana potreba za mrežnim resursima i učinkovitim raspolaganjem dostupnom propusnosti. U tradicionalnim uslugama za prijenos videosignala prijenosna brzina ostvarena kodiranjem (engl. *bitrate*) izravno određuje kvalitetu videosignala. Međutim, ako se za prijenos videosignala koristi visoka kodna prijenosna brzina, iskustvo gledanja videosignala krajnjeg korisnika može biti lošije zbog ograničene dostupne propusnosti mreže. Ograničena dostupna propusnost mreže kao posljedicu ima na primjer česte prekide u reprodukciji videosignala čime se smanjuje fluidnost prikazivanja videosignala i smanjuje se kvaliteta korisničkog iskustva.

Kako bi se zadovoljile potrebe korisnika za uslugama videostrujanja kod kuće, kao i u pokretu te uzimajući u obzir različite uređaje i njihove mogućnosti, razvijene su različite tehnologije za prijenos videosignala. Tehnologije za videostrujanje prilagodljivo mrežnim uvjetima zasnovane na HTTP-u predstavile su značajan napredak u prijenosu videosignala visoke kvalitete do krajnjih korisnika. S obzirom da tijekom prijenosa dolazi do stalnih promjena u dostupnoj propusnosti mreže, algoritmi za prilagodljivo videostrujanje stalno prilagođavaju kodnu prijenosnu brzinu videosignala [8].

Postoji nekoliko rješenja za prilagodljivo videostrujanje koja su razvila privatna poduzeća kao što su Microsoft Smooth Streaming, Apple HTTP Live Streaming (HLS) i Adobe *HTTP* Dynamic Streaming. U dostupnoj literaturi najčešće se za potrebe ispitivanja novih korisničkih aplikacija koristio HLS. HLS je komunikacijski protokol za prijenos multimedijalnog signala temeljen na HTTP protokolu koji se koristi za prijenos vezanih i nevezanih prijenosnih tokova multimedijskih podataka [9]. Ova metoda djeluje kroz vatrozide i *proxy* poslužitelje te se oslanja na standardni HTTP zahtjev [10] za preuzimanje datoteka. Sva tri spomenuta rješenja osiguravaju prilagodljivo videostrujanje na način da koriste različite varijante istog videosignala. Svaka varijanta je kodirana različitim prijenosnim brzinama i dodatno podijeljena u male segmente. U ovisnosti o uvjetima u mreži korisnička aplikacije može odabrati odgovarajuću varijantu videosignala s većom odnosno manjom prijenosnom brzinom kako bi se prilagodila uvjetima u mreži [11].

U rješenjima za prilagodljivo videostrujanje poput Microsoft Smooth Streaming, Apple HTTP Live Streaming i Adobe HTTP Dynamic Streaming, korisnički uređaji morali su podržavati korisnički protokol proizvođača. Nadalje, ova rješenja su bila zaštićena autorskim pravima te nisu bila interoperabilna budući da su koristila različite formate segmenata i manifest datoteka [12]. Kako bi se riješili spomenuti problemi, MPEG i 3rd Generation Partnership Project (3GPP) predložili su globalnu normu pod nazivom MPEG DASH.

2.1. MPEG DASH norma

U travnju 2009. godine MPEG grupacija objavila je poziv za dostavu prijedloga za HTTP normu za prilagodljivo videostrujanje. Na osnovu ukupno petnaest dostavljenih prijedloga te uz pomoć brojnih stručnjaka i suradnje s 3GPP izrađena je specifikacija MPEG DASH norme [13]. Razvoj prve završne verzije MPEG DASH norme, danas poznate kao ISO/IEC 23009-1, bio je završen u kolovozu 2011. godine, a ratificirana je prije MPEG-98 (98. sastanak MPEG) koji je održan u prosincu 2011. godine. MPEG DASH objavljen je kao norma od strane Međunarodne organizacija za standardizaciju (engl. *International Standardization Organization* - ISO) u travnju 2012. godine. MPEG DASH specifikacija daje opis sadržaja pohranjenog na HTTP poslužitelju. Sadržaj koji se sprema na poslužitelj može se podijeliti na dva dijela: datoteka za opis prikaza medija (engl. *Media Presentation Description* -MPD) i videosegmenti [8].

MPEG DASH norma [14] određuje način obavještavanja korisnika o dostupnosti niza prijenosnih tokova različite kvalitete zajedno s informacijama potrebnim za odabir odgovarajućeg prijenosnog toka. Također definira formate medijskih datoteka pogodnih za prilagodljivo videostrujanje. Postojanje različitih formata datoteka omogućuje učinkovito i neprimjetno prebacivanje između prijenosnih tokova različite kvalitete što omogućuje prilagodbu promjenjivim uvjetima u mreži bez zaustavljanja reprodukcije videosignala.

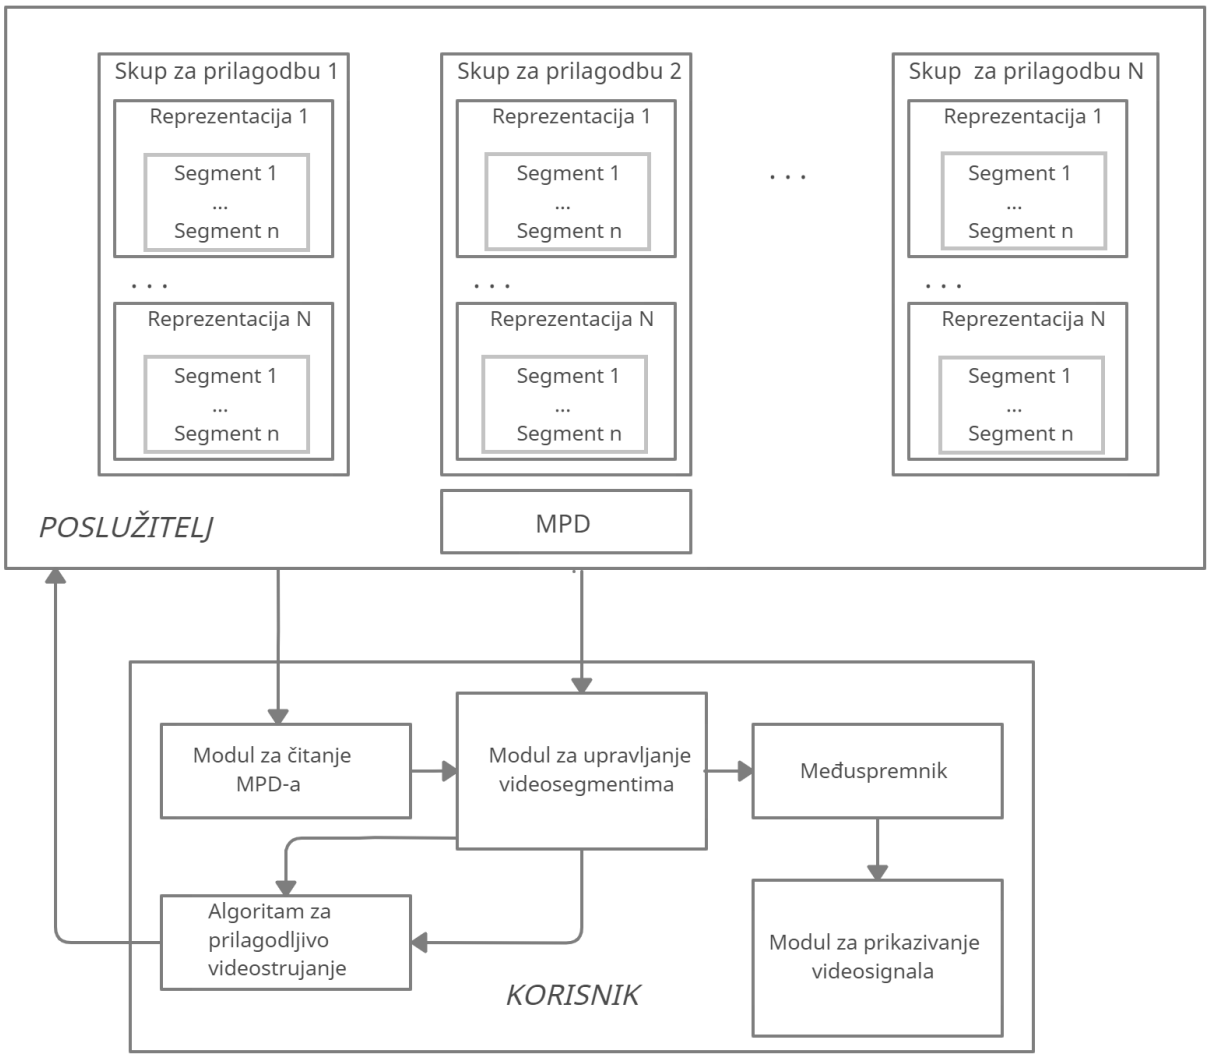
MPEG DASH norma razvijena je kako bi se pojednostavilo održavanje aplikacija, smanjili troškovi razvoja i osigurala interoperabilnost korisničkih aplikacija i poslužitelja. Svaki sustav razvijen u skladu s MPEG DASH normom pruža glatku reprodukciju zahvaljujući algoritmu za prilagodljivo videostrujanje koji odabire odgovarajuće videosegmente kodirane različitim prostornim rezolucijama i kodnim brzinama u ovisnosti o karakteristikama korisničkih uređaja i stanja u heterogenoj mreži [5]. Glatka reprodukcija osigurana je praćenjem dostupne propusnosti i brzine preuzimanja kodiranog sadržaja. Da bi se spriječilo stanje nedovoljne popunjenosti međuspremnika i zaustavljanja reprodukcije videosignala u slučaju smanjene dostupne propusnosti mreže, korisnička aplikacija može odabrati odgovarajuće videosegmente s nižom kvalitetom. Korisnik također može odabrati tok s većom kodnom brzinom ako je brzina preuzimanja veća od kodne brzine trenutnog toka [15]. Logika prilagodbe u DASH sustavima ima za cilj pružiti najvišu moguću kvalitetu korisničkog iskustva uzimajući u obzir parametre poput dostupne propusnosti i popunjenosti međuspremnika [16].

Iako se algoritmi za prilagodljivo videostrujanje istražuju još od 2011. godine, istraživači ga i dalje pokušavaju unaprijediti kako bi se postigle bolje performanse i ostvarila bolja kvaliteta korisničkog iskustva.

2.1.1. Sustav za prilagodljivo videostrujanje zasnovan na MPEG DASH normi

Svaki sustav zasnovan na MPEG DASH normi sastoji se od korisničke aplikacije i poslužitelja. Korisnička aplikacija i poslužitelj u DASH sustavima komuniciraju pomoću HTTP GET zahtjeva i rade preko *proxy* poslužitelja i vatrozida [17]. Osim modula koji sadrži logiku za prilagodbu prijenosne brzine, korisnička aplikacija sastoji se od nekoliko dodatnih modula poput modula za prikazivanje videosignala, modula za analizu MPD datoteke, modula za prikupljanje i distribuciju videosegmenata te međuspremnika (Slika 2.1.). Poslužitelj se koristi za spremanje MPD datoteka i segmentiranih videosignala.

MPEG DASH norma ne definira parametre segmentacije videosignala, niti definira broj reprezentacija za pojedini videosignal, komunikaciju između poslužitelja i korisničke aplikacije, kao ni ponašanje korisničke aplikacije.



Slika 2.1. Arhitektura sustava zasnovanog na MPEG DASH normi

MPEG DASH definira samo format segmenata i MPD datoteke. MPD je manifest datoteka koja pruža informacije o dostupnim skupovima prilagodbe (engl. *adaptation set*) i skupovima reprezentacija. Može se prenijeti pomoću HTTP-a, elektronskom poštom ili putem drugih dostupnih komunikacijskih kanala. MPD datoteka je datoteka *Extensible Markup Language* (XML) formata koja pohranjuje informacije o koderu, trajanju videosignala, vremenskom rasponu (engl. *timescale*), dostupnim skupovima prilagodbe, skupovima reprezentacija, prostornim rezolucijama, dostupnim prijenosnim brzinama, *Uniform Resource Locator* (URL) adresama za svaki medijski videosegment i početni segment za inicijalizaciju dekodera [18, 19].

Kao što se može vidjeti na slici 2.1, videosegmenti su organizirani u skupove prilagodbe i skupove reprezentacija. Na poslužitelju može biti pohranjen jedan ili više skupova prilagodbe za određeni videosignal. Skupovi prilagodbe mogu se razlikovati prema prostornoj rezoluciji ili prema vrsti multimedijske komponente (video, zvuk, podnaslov (engl. *subtitle*)). Unutar jednog skupa prilagodbe obično postoji više reprezentacija (10-20), koje sadrže kodirani i segmentirani videosignal, pri čemu je za svaku reprezentaciju videosignal kodiran drugom kodnom brzinom. Uobičajeno je da se pri tome koriste niže prostorne, a ponekad i niže vremenske rezolucije za niže kodne brzine. Treba napomenuti da se ciljana kodna brzina (postavljena kao parametar kod kodiranja) može razlikovati od postignutih vrijednosti kodne prijenosne brzine. Broj segmenata za određeni videosignal u jednoj reprezentaciji određen je trajanjem videosignala i unaprijed definiranom vrijednošću trajanja svakog videosegmenta. Trajanje videosegmenta najčešće je 1, 2, 4, 6, 8, 10 ili 12 sekundi.

Prije segmentiranja videosignala za prilagodljivo strujanje, svaki se videosignal treba kodirati pomoću unaprijed određenih parametara kodiranja koji imaju velik utjecaj na kvalitetu korisničkog iskustva [12, 19].

Svaki je segment određen veličinom grupe slika (engl. *Group Of Pictures* - GOP) i započinje s I slikom i ima više P i B slika. Zbog činjenice da se I slika kodira odvojeno od ostalih slika, kraći segmenti prikladniji su za primjenu u promjenjivim mrežnim uvjetima jer segmenti s većim GOP-om trebaju više vremena za preuzimanje [19]. Prilikom kodiranja vrijednost duljine GOP-a postavlja se na vrijednost koja odgovara umnošku željenog trajanja videosegmenta i vremenske rezolucije videosignala. Segmenti s kraćim trajanjem imaju kraći GOP pa tako osiguravaju i manji broj zastoja i prekida tijekom videostrujanja. Segmenti s dužim trajanjem imaju manji broj I-slika, pa je ukupna prosječna veličina segmenta niža [19, 20] što štedi prostor na poslužitelju. Problem sa segmentima s kraćim trajanjem također je broj HTTP signalnih poruka ako se ne koristi

aplikacija koja ima mogućnost traženja više segmenata s jednim HTTP zahtjevom. Ovo je rješenje posebno zanimljivo za primjenu u uslugama strujanja videosignala uživo gdje se mogu koristiti segmenti kraći od jedne sekunde. Nakon kodiranja i segmentacije, videosegmenti se pohranjuju na poslužitelj zajedno s MPD datotekom i početnim segmentom za inicijalizaciju dekodera [21-23].

Prvi stvoreni segment naziva se inicijalizacijski segment ili početni segment i ne sadrži medijske podatke. Početni segment je neophodan jer sadrži sve informacije potrebne za inicijalizaciju dekodera na korisničkoj strani [12, 24]. Svaki skup prilagodbe ima svoj početni segment.

MPD datoteka ima šest profila propisanih MPEG DASH normom:

- urn:mpeg:dash:profile:full:2011
- urn:mpeg:dash:profile:isoff-on-demand:2011
- urn:mpeg:dash:profile:isoff-live:2011
- urn:mpeg:dash:profile:isoff-main:2011
- urn:mpeg:dash:profile:mp2t-main:2011
- urn:mpeg:dash:profile:mp2t-simple:2011

Profili su definirani normom kako bi se omogućila interoperabilnost i signalizacija prilikom korištenja različitih značajki sustava (engl. *features*). Profil također nameće i niz posebnih ograničenja. Ograničenja se prvenstveno odnose na format MPD datoteke i segmenata, ali se mogu odnositi i na sadržaj dostavljen u segmentima (primjerice vrste medijskog sadržaja, medijskih formata, kodeka i zaštite, ili na primjer kvantitativne mjere kao što su prijenosna brzina, trajanje i veličine segmenata) [25].

Osim modula za upravljanje segmentima na korisničkoj strani, ostali moduli MPEG DASH korisničke aplikacije nisu specifični za svaki pojedini profil, što olakšava izradu i korištenje različitih profila zbog ponovne uporabe tih modula.

S obzirom da modul za upravljanje segmentima ovisi o korištenom MPD profilu, važno je da ima jednostavno i jasno definirano sučelje za komunikaciju s ostalim modulima. Ovo sučelje kao ulazne parametre uzima parametre MPD datoteke te mora imati poveznicu s poslužiteljem i s modulom koji sadrži algoritam za prilagodljivo videostrujanje. Povratna informacija modula za upravljanje segmentima su segmenti spremni za reprodukciju u nekom od alata za prikaz medijskog sadržaja [26].

Komunikacija između poslužitelja i korisničke aplikacije započinje slanjem HTTP GET zahtjeva za MPD datotekom željenog videosignala. MPD datoteka se zatim čita u korisničkoj aplikaciji i pohranjuju se informacije o dostupnim skupovima prilagodbe, reprezentacijama, URL adresama segmenata, vrstama medija, prostornoj rezoluciji, minimalnoj i maksimalnoj prijenosnoj brzini, postojanju kodiranih alternativa multimedijskih komponenti i drugim karakteristikama sadržaja. Korisnik zatim na temelju podataka dobivenih u svakom od elemenata skupa prilagodbe odabire skup prilagodbe koji odgovara okruženju [17, 27].

Zatim se unutar odabranog skupa prilagodbe odabire reprezentacija. Reprezentacija se u pravilu odabire na osnovu dostupne propusnosti mreže, ali uzimaju se u obzir i brzina dekodiranja i učitavanja sadržaja. 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.

Nakon preuzimanja prvog segmenta koji sadrži medijske podatke i koji je obično iz reprezentacije kodirane s najnižom kodnom brzinom, koristi se algoritam za prilagodljivo videostrujanje koji određuje sljedeću najprikladniju reprezentaciju unutar odabranog skupa prilagodbe. Nakon preuzimanja prvog segmenta, korisnička aplikacija također gradi vremensku liniju i određuje pristupnu točku toka podataka (engl. *Stream Access Point* - SAP) za svaki od medijskih tokova podataka u različitim reprezentacijama. Nakon definiranja SAP-a može se započeti prikazivanje videosignala. Jednom nakon što je započelo prikazivanje sadržaja, korisnička aplikacija nastavlja prikaz medijskog sadržaja, odnosno kontinuirano traži medijske segmente ili dijelove medijskih segmenata [17, 27].

Na temelju mjerenja različitih parametara poput dostupne propusnosti i zauzetosti međuspremnika odabire se reprezentacija za sljedeći videosegment i šalje se zahtjev za dohvaćanje segmenta kako bi se osigurala neometana reprodukcija [12]. Minimalni vremenski period potreban da korisnička aplikacija učita medijski zapis jednak je najmanjem vremenskom periodu učitavanja prije početka prikazivanja videosignala.

Korisnička aplikacija može promijeniti reprezentaciju sa svakim zahtjevom za medijski segment koji sadrži pristupnu točku uzimajući u obzir ažurirane podatke MPD i / ili ažurirane informacije iz svoje okoline, npr. promjena propusnosti. Neprimjetno prebacivanje između reprezentacija ostvaruje se zahvaljujući činjenici da su segmenti unutar reprezentacija unutar jednog skupa prilagodbe vremenski usklađeni [28].

Sustavi za prilagodljivo videostrujanje omogućuje bolju ravnotežu između parametara koji utječu na kvalitetu korisničkog iskustva primjenom algoritama za prilagodljivo videostrujanje koji kontinuirano prilagođavaju prijenosnu brzinu uvjetima u mreži.

Glavni problem algoritama za prilagodljivo videostrujanje je kako precizno predvidjeti vrijeme potrebno za preuzimanje sljedećeg videosegmenta kako bi se osiguralo da se segment preuzme prije nego što modul za prikazivanje videosadržaja iskoristi sve videosegmente koji se nalaze u međuspremniku. Zbog nepredvidivih mrežnih uvjeta nije lako procijeniti dostupnu propusnost na temelju prošlih vrijednosti parametara mreže. Također, može se pojaviti problem spore konvergencije do optimalne prijenosne brzine, kao i često prebacivanje između razina kvalitete (reprezentacija), što negativno utječe na kvalitetu korisničkog iskustva. Kako bi se postigle bolje performanse sustava zasnovanih na MPEG DASH normi i ostvarila viša razina kvalitete korisničkog iskustva, algoritmi za prilagodljivo strujanje tema su istraživanja još od objave MPEG DASH norme [4, 10].

2.1.2. Algoritmi za prilagodbu prijenosne brzine kod prilagodljivog videostrujanja

ABR algoritmi za prilagodljivo videostrujanje koji se koriste u MPEG DASH korisničkim aplikacijama, mogu se podijeliti u nekoliko glavnih skupina:

- algoritmi zasnovani na dostupnoj propusnosti,
- algoritmi zasnovani na popunjenosti međuspremnika i dostupnoj propusnosti,
- hibridni algoritmi.

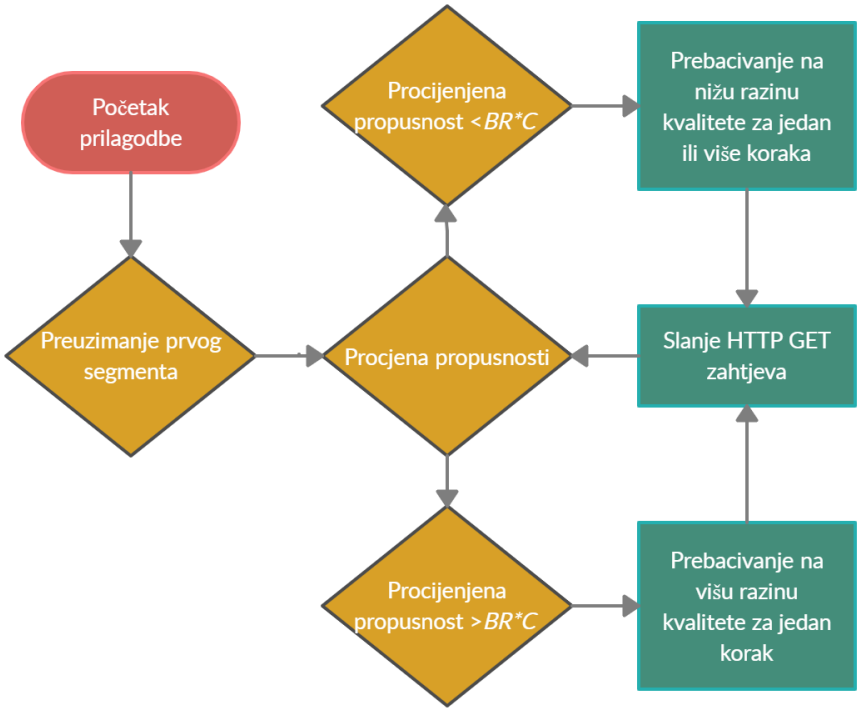
Iako je tijekom godina bilo predloženo mnogo algoritama za prilagodljivo videostrujanje, u nedavnim su se istraživanjima znanstvenici usredotočili na razvoj algoritama koji u obzir uzimaju i parametre kvalitete korisničkog iskustva. ABR algoritmi podijeljeni su u skupine na temelju parametara koje uzimaju u obzir u procesu donošenja odluka pri odabiru sljedeće razine kvalitete odnosno reprezentacije.

2.1.2.1. Algoritmi zasnovani na dostupnoj propusnosti

Prvi algoritmi predloženi u literaturi bili su upravo algoritmi za prilagodljivo videostrujanje koji su u obzir uzimaju dostupnu propusnost mreže, ali su imali i određenu donju graničnu vrijednost popunjenosti međuspremnika.

LIU algoritam predložen u [29] najkorišteniji je algoritam u dostupnoj literaturi. Koristi vrijeme dohvaćanja prethodnih segmenata za mjerenje srednje vrijednosti propusnosti te prema tome odabire reprezentaciju za sljedeći videosegment. Vrijeme preuzimanja segmenta određuje se kao

vrijeme između HTTP GET zahtjeva i primanja zadnjeg bita traženog videosegmenta. Dijagram toka LIU algoritma za prilagodljivo strujanje prikazan je slikom 2.3. Na početku videostrujanja, LIU algoritam odabire segment na najnižoj ponuđenoj razini kvalitete.



Slika 2.3. Dijagram toka LIU algoritma za prilagodljivo strujanje videosadržaja.

Nakon preuzimanja prvog segmenta, LIU prepoznaje dva scenarija prilagodbe na temelju procijenjene propusnosti mreže, koja se izračunava pomoću vremena potrebnog za dohvaćanje prethodnih N segmenata. U prvom scenariju, ako je dostupna propusnost veća od unaprijed definirane granične vrijednosti ($BR \cdot C$, gdje je BR prijenosna brzina odabrane reprezentacije za pretdono preuzeti segment, a C unaprijed definirana konstanta), postupno se bira viša razina kvalitete svakog sljedećeg segmenta. Ovaj scenarij zadržava popunjenost međuspremnika dovoljno visoko kako bi se osigurala reprodukcija videosignala s najmanjim mogućim brojem zastoja u reprodukciji. Također, ovaj scenarij smanjuje početno kašnjenje, poboljšavajući tako QoE korisnika. U drugom scenariju, ako je raspoloživa propusnost manja od unaprijed definirane granične vrijednosti, sljedeća odabrana reprezentacija može biti niža i za nekoliko razina. Ovaj scenarij sprječava neželjeno pražnjenje međuspremnika i zaustavljanje reprodukcije videosadržaja smanjenjem razine kvalitete na razinu kvalitete koja odgovara procijenjenim uvjetima u mreži. Reprezentacija odabranog segmenta je u ovom slučaju jednu ili više razina niža od reprezentacije zadnjeg prenesenog videosegmenta.

LIU algoritam osigurava glatku reprodukciju primjenom kratkog odgađanja početka prikazivanja videosignala čime osigurava i mali broj kasnijih zastoja u reprodukciji uz izbjegavanje agresivnog prebacivanja razina kvalitete.

Jedan od dostupnih algoritama koji predstavlja nadogradnju na LIU algoritam opisan je u [30]. Predloženi algoritam za prilagodljivo videostrujanje odabire sljedeću razinu kvalitete pomoću procjene propusnosti koja je određena unaprijed definiranim rasponom vrijednosti uzimajući u obzir težinski faktor: postotna promjena propusnosti (engl. *Sliding Percentile* - SP). Algoritam prati vrijednosti prethodno dostupne propusnosti kako bi se omogućila brza konvergencija u slučaju značajnih promjena u mreži i kako bi vrijednosti procijenjene propusnost tvorile glatku krivulju. Vrijednosti prethodno dostupnih propusnosti određuju su kao srednje vrijednosti *N* procijenjenih propusnosti. Korištenjem predloženog algoritma poboljšava se prosječna ocjena kvalitete korisničkog iskustva u odnosu na LIU algoritam. Također, nastanak zastoja u reprodukciji se smanjuje procjenom sljedeće razine dostupne propusnosti na temelju prosječne propusnosti i praćenjem pokazatelja granične vrijednosti popunjenosti međuspremnika. Predložena implementacija algoritma za prilagodljivo videostrujanje postiže veći prosječni QoE i ostvaruje veću stabilnost u različitim mrežnim uvjetima u odnosu na prethodno spomenuti algoritam. Također, predloženi algoritam ima manji broj prebacivanja između dostupnih reprezentacija u usporedbi s LIU pri istim uvjetima u mreži.

Jedan od novijih ABR algoritama koji odluku o sljedećoj reprezentaciji donosi na osnovu dostupne propusnosti opisan je u [31]. Algoritam za sustave zasnovane na MPEG DASH normi koji u obzir uzima i QoE (QDASH) integrira mjerenje dostupne propusnosti i procjenu kvalitete korisničkog iskustva. Predloženi DASH sustav sastoji se od dva modula, prvi modul mjeri raspoloživu propusnost, a drugi određuje razinu kvalitete videosignala. Modul koji je zadužen za mjerenje mrežne propusnosti ima preciznu metodologiju za određivanje najviše razine kvalitete koju mreža može podržati i osjetljiv je na promjene u dostupnoj propusnosti. QDASH kao i prethodni algoritmi koristi međuspremnik kako bi smanjio mogućnost prekida reprodukcije. Ispitivanjem QDASH algoritma zaključeno je da korisnici preferiraju postupnu promjenu kvalitete između najbolje i najlošije razine kvalitete, umjesto naglog prebacivanja između razina kvalitete. U usporedbi s prethodno razvijenim algoritmima, zaključeno je da se utjecaj naglih promjena razina kvalitete na kvalitetu korisničkog iskustva može smanjiti uvođenjem dodatne „srednje“ razine kvalitete. Korisnici su preferirali reprodukciju videosignala s ubačenom dodatnom razinom kvalitete u slučaju kada je bilo potrebno smanjiti razinu kvalitete i nisu znali da gledaju videosignal najniže kvalitete ako nije bilo jasnih prijelaza između razina kvalitete.

Slično kao i svi prethodni algoritmi, algoritam opisan u [32] čuva minimalnu popunjenost međuspremnika kako bi se izbjegli zastoji u reprodukciji i minimalizira broj prebacivanja između razina kvalitete videosignala tijekom reprodukcije. Algoritam za prilagodljivo videostrujanje uz poboljšanu kvalitetu korisničkog iskustva (engl. *QoE-enhanced Adaptation Algorithm over DASH* – QAAD) zasnovan je također na propusnosti. QAAD sadrži modul za procjenu propusnost i modul za odabir prijenosne brzine. U modulu za procjenu dostupne propusnosti, raspoloživa propusnost se procjenjuje na temelju prethodno preuzetih segmenata i izvještava se modul za odabir prijenosne brzine. Dio algoritma za odabir prijenosne brzine poziva se na kraju svakog preuzimanja segmenta. U usporedbi s QDASH-om koji često mijenja kvalitetu videosignala i zbog čega može doći do zastoja i prekida u reprodukciji videosignala, QAAD omogućuje neometano strujanje sa stabiliziranom kvalitetom videosignala. QAAD također daje precizniju procjenu propusnosti i točniji je u odabiru sljedeće reprezentacije. QDASH je također osjetljiviji na promjene propusnost mreže, jer QAAD povećava prijenosnu brzinu na konzervativniji način, čak i kada se mrežna propusnost povećava.

2.1.2.2. Algoritmi zasnovani na popunjenosti međuspremnika i dostupnoj propusnosti

S obzirom da postoji cijeli niz ABR algoritama koji odluku o razini kvalitete sljedećeg segmenta donose uzimajući u obzir popunjenost međuspremnika i procijenjenu dostupnu propusnost, u ovom potpoglavlju bit će spomenuto samo nekoliko novijih algoritama koji analiziraju kvalitetu korisničkog iskustva.

Algoritam za prilagodljivo strujanje videosignala putem HTTP-a opisan u [33] maksimizira ukupni QoE za krajnje korisnike, a istovremeno sprječava pražnjenje međuspremnika ispod unaprijed definirane granične vrijednosti. Prije nego što je razvijen sam algoritam, predložen je model za ocjenjivanje kvalitete korisničkog iskustva u videostrujanju zasnovan na održavanju kontinuiteta reprodukcije koji u obzir uzima popunjenost međuspremnika, kvalitetu medijskog segmenta i promjene u percipiranoj kvaliteti koje su uzrokovane prebacivanjem prijenosne brzine. U usporedbi s ranije spomenutim algoritmima, predloženi algoritam postiže gotovo optimalan kompromis između ukupnog kontinuiteta reprodukcije i QoE.

ABR algoritam za prilagodljivo strujanje videosignala putem HTTP-a opisan u [34] je prvi algoritam koji osim promjena u dostupnoj propusnosti mreže i popunjenosti međuspremnika prilikom odluke o razini kvalitete za sljedeći segment uzima u obzir i stvarne prijenosne brzine svakog pojedinog videosegmenta. Predloženi algoritam ostvaruje povećanje vrijednosti QoE kod 17 do 45% ispitanika u usporedbi s drugim algoritmima zbog činjenice da osigurava kompromis

među parametara koje promatra: kvalitete primljenog videosignala, broja zastoja u reprodukciji, trajanja zastoja u reprodukciji i broja prebacivanja razina kvalitete videosignala. U usporedbi s drugim algoritmima koji u obzir uzimaju popunjenost međuspremnika, predloženi algoritam smanjuje zastoje u reprodukciji videosignala za 33%, istovremeno osiguravajući približno jednaku prosječnu kvalitetu videosignala i približno jedak broj prebacivanja razina kvalitete u slučaju međuspremnika duljine 60 sekundi i veličine segmenta od četiri sekunde.

ABR algoritam opisan u [35] uzima u obzir raspoloživu propusnost i upravlja međuspremnikom na način da ga ispunjava visokokvalitetnim segmentima u uvjetima visoke dostupne propusnosti, poboljšavajući tako kvalitetu korisničkog iskustva. Propusnost nadolazećih segmenata procjenjuje se na temelju prethodno promatrane propusnosti što rezultira stabilnijom popunjenosti međuspremnika. U slučaju pogoršanja mrežnih uvjeta preuzimaju se segmenti niže kvalitete. Kada se poboljšaju mrežni uvjeti, korisnička aplikacija prvo reproducira segmente niske kvalitete kako bi se segmenti više kvalitete mogli preuzeti. Kada segmenti više kvalitete postanu dostupni, algoritam odbacuje segmente niže kvalitete koji se nalaze u međuspremniku i reproducira segmente više razine kvalitete preuzete u uvjetima veće dostupne propusnosti. Predložena shema smanjuje broj prebacivanja razina kvalitete u usporedbi s osnovnim algoritmom (LIU). Ukupna kvaliteta videosignala poboljšana je u odnosu na prethodno dostupne algoritme.

U [36] predložen je ABR algoritam za prilagodljivo videostrujanje koji uključuje unutarnju funkciju s ciljanom QoE u mehanizam odlučivanja te održava dobru ravnotežu između različitih zahtjeva. MPD datoteka proširena je s prethodno određenim prijenosnim brzinama svakog pojedinog segmenta kako bi odabir segmenta mogao pratiti promjene dostupne propusnosti. U usporedbi s drugim algoritmima, ovaj algoritam osigurava povećanu robusnost i preciznije predviđanje dostupne propusnosti. U mreži bez brzih promjena u dostupnoj propusnosti, predloženi algoritam ostvaruje poboljšanje kvalitete korisničkog iskustva za 27% u odnosu na osnovni algoritam zasnovan samo na popunjenosti međuspremnika i 138% u odnosu na prethodno razvijeni algoritam zasnovan na popunjenosti međuspremnika koji uzima u obzir podatke o procijenjenoj dostupnoj propusnosti. U mreži s brzim promjenama u dostupnoj propusnosti poboljšanja su 78%, odnosno 172%.

2.1.2.3. Hibridni ABR algoritmi

U hibridne ABR algoritme pripadaju svi algoritmi koji osim dostupne propusnosti odnosno procijenjene dostupne propusnosti i popunjenosti međuspremnika u obzir uzimaju i druge parametre kao što veličina pojedinog segmenta, karakteristike videosadržaja i sl.

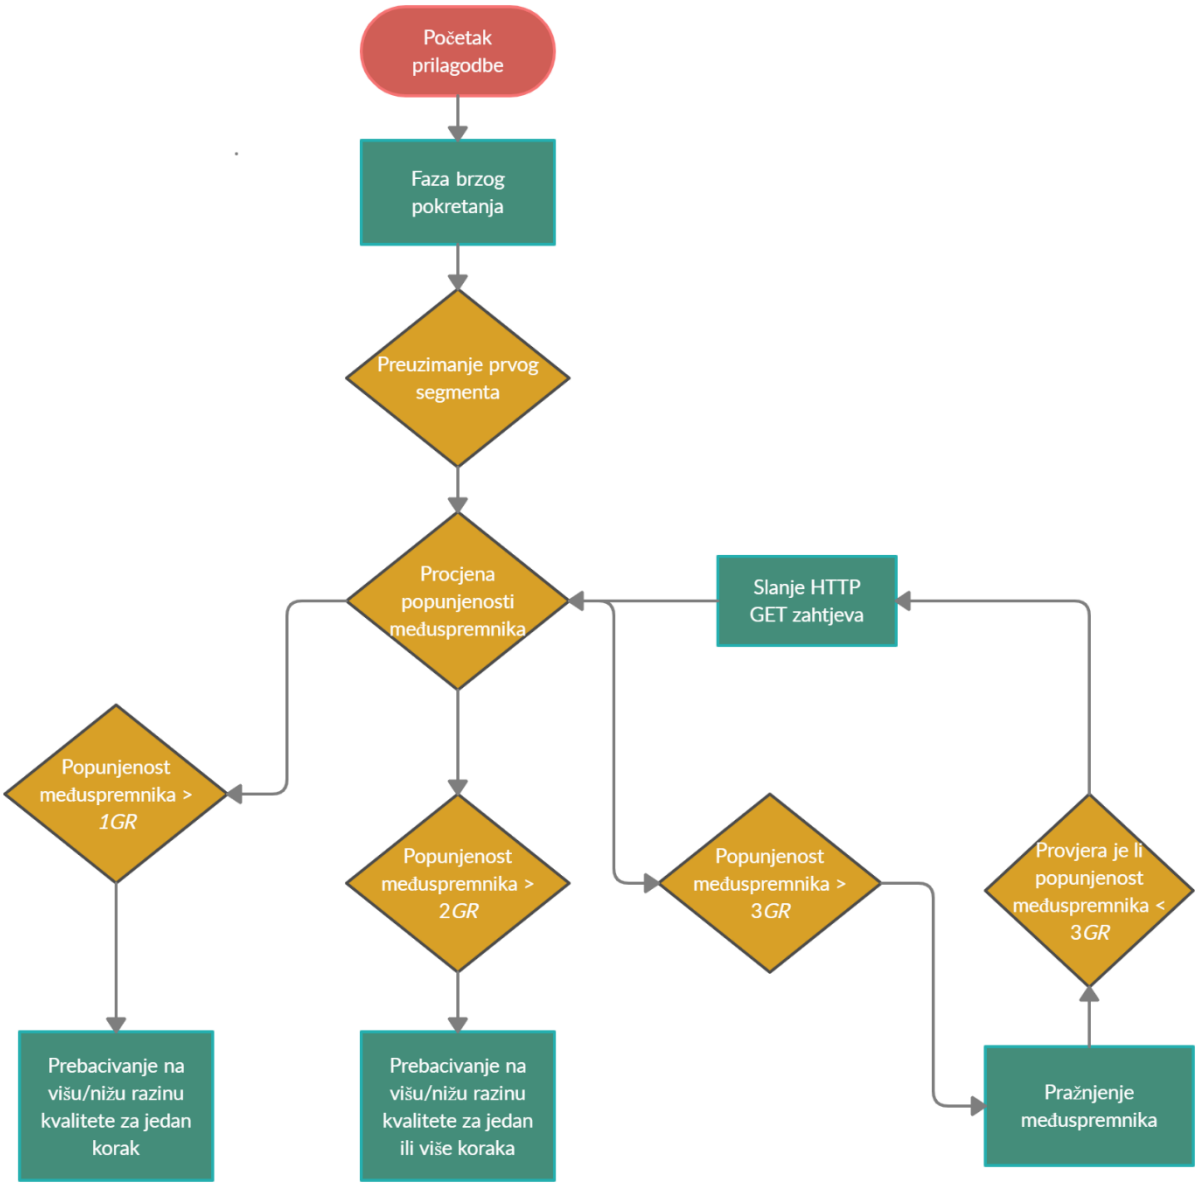
Najpoznatiji i u ispitivanjima, osim LIU, najkorišteniji algoritam za prilagodljivo videostrujanje je algoritam za prilagodbu prijenosne brzine koji u obzir uzima u veličinu segmenta (engl. *Segment-Aware Rate Adaptation* - SARA) [37]. SARA algoritam stoga koristi poboljšanu verziju MPD datoteke koja sadrži informacije o veličini svakog segmenta, zajedno s ostalim informacijama potrebnim za prilagodljivo videostrujanje.

Razina kvalitete sljedećeg segmenta kod SARA algoritma odabire se uzimajući u obzir izmjerenu propusnost, popunjenost međuspremnika i varijacije u veličinama segmenata što posljedično znači poboljšanje kvalitete korisničkog iskustva u MPEG DASH sustavu. Ovo je prvi algoritam opisan u literaturi koji uzima u obzir činjenicu da se veličine segmenata mogu razlikovati neovisno što imaju iste parametre kodiranja i segmentacije. U slučaju mreže s niskom dostupnom propusnosti, promjene u veličinama segmenata rezultiraju netočnom procjenom optimalne prijenosne brzine zbog netočne procjene očekivanih vremena preuzimanja segmenta. Dijagram toka SARA algoritma za prilagodljivo strujanje videosignala prikazan je slikom 2.4.

Međuspremnik modeliran SARA algoritmom koji sadrži sve preuzete segmente prepoznaje tri granične vrijednosti koje su definirane brojem segmenata u međuspremniku. Ovisno o popunjenosti međuspremnika, odabir odgovarajuće razine kvalitete odnosno reprezentacije vrši se u četiri faze:

- faza brzog pokretanja - razina međuspremnika je ispod prve granične vrijednosti. U ovoj se fazi odabire se najniža dostupna razina kvalitete kako bi se smanjilo vrijeme potrebno za prikaz videosignala,
- faza postupnog povećanja prijenosne brzine - razina popunjenosti međuspremnika veća je od prve granične vrijednosti (*1GR*). U ovoj fazi razina kvalitete se mijenjati postupno, tj. samo jedan korak gore ili dolje tako da popunjenost međuspremnika ne padne ispod prve granične vrijednosti,
- faza agresivnog povećanja prijenosne brzine - razina popunjenosti međuspremnika veća je od druge granične vrijednosti (*2GR*). U ovoj fazi razina kvalitete se mijenja u ovisnosti o dostupnoj propusnosti za jedan ili više koraka.
- faza preuzimanja segmenta s povećanim kašnjenjem - događa se kada se razina međuspremnika poveća iznad treće granične vrijednosti (*3GR*). U ovoj se fazi zahtjev za novim segmentom šalje samo kad se razina popunjenosti međuspremnika spusti na vrijednost treće granične vrijednosti. U ovoj fazi postoji ograničenje ukupnog broja segmenata u međuspremniku, tako da se izbjegne nepotrebno preuzimanje segmenta (korisnici mogu prestati gledati videosignal prije kraja njegove reprodukcije).

SARA ostvaruje veću prosječnu razinu kvalitete videosignala i kvalitete korisničkog iskustva u odnosu na algoritme koji ne uzimaju u obzir veličinu segmenta u slučaju kada je prosječna razina dostupne propusnosti niska [37].



Slika 2.4. Dijagram toka algoritma SARA.

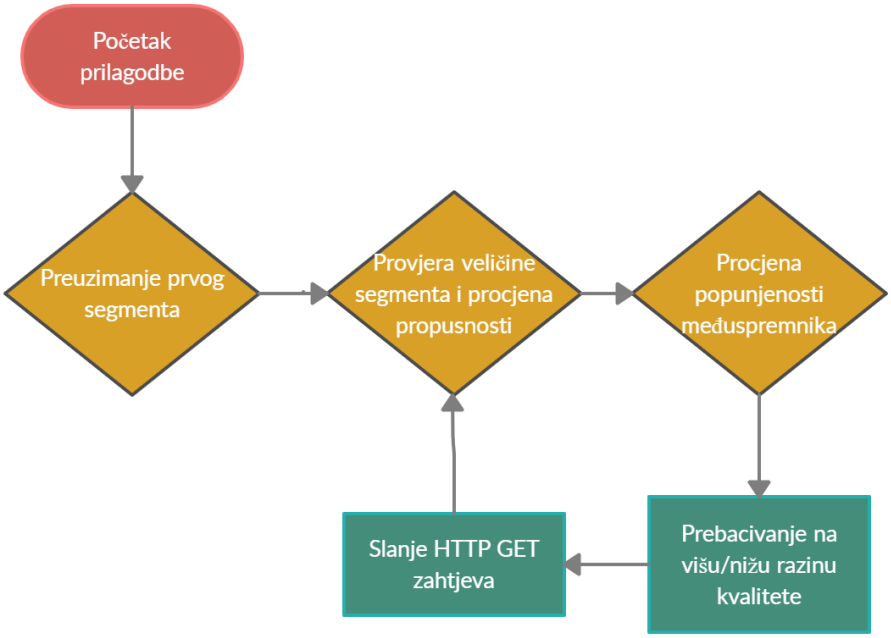
ABR algoritam za prilagodljivo strujanje videosignala opisan u [38] također poboljšava QoE korištenjem MPD datoteke nadopunjene veličinom segmenta uz pomoć kontrole kvalitete segmenta. Algoritam je razvijen na način da kada popunjenost međuspremnika nije dovoljna za reprodukciju videosignala do preuzimanja sljedećeg segmenta na trenutnoj razini kvalitete, razina kvalitete će se smanjiti. U slučaju kada je popunjenost međuspremnika dovoljna za reprodukciju videosignala, čak i slučaju kada se dostupna propusnost drastično smanji, razina kvalitete će se

povećati. Ispitivanje sustava pokazalo je da ovaj poboljšani algoritam za prilagodljivo strujanje videosignala omogućuje neometanu reprodukciju i glatku promjenu razina kvalitete. Nadalje, predloženi algoritam dulje održava veću razinu kvalitete u odnosu na prethodne algoritme kada se dostupna propusnost smanjuje zbog činjenice da određuje razinu kvalitete na temelju popunjenosti međuspremnika. Kratkotrajne promjene u dostupnoj propusnosti tako manje utječu na prosječnu razinu kvalitete u usporedbi s algoritmima na koji su zasnovani samo na procjeni propusnosti.

U usporedbi s algoritmima koji u slučaju zastoja u reprodukciji videosignala smanjuju brzinu prijenosa kako bi se uklonila mogućnost pada popunjenosti međuspremnika ispod donje granične vrijednosti, algoritam opisan u [39] osigurava poboljšanje QoE na način da se razina kvalitete segmenta odabire na način da se pokušava održati neprekidna usluga strujanja bez obzira na mogućnost pada popunjenosti međuspremnika. Razina kvalitete sljedećeg segmenta određuje se prema unaprijed određenim graničnim vrijednostima za svaku razinu kvalitete koju određuju korisničke aplikacije s različitim zahtjevima za kvalitetom videosignala. Ispitivanjima je dokazano da u slučaju mobilnih korisnika, u MPEG DASH aplikacijama predloženi način prilagodbe prijenosne brzine povećava prosječnu razinu kvalitete u odnosu na druga rješenja.

ABR algoritam za prilagodljivo strujanje videosignala opisan u [40] prvi je algoritam za videostrujanje koji u obzir uzima složenost sadržaja videosignala (engl. *Content-Aware Rate Adaptation* - CARA). Predloženi algoritam prilikom odabira razine kvalitete za sljedeći segment u obzir uzima sadržaj videosignala, veličine pojedinih segmenata i prilagođava prijenosnu brzinu na temelju promjene dostupnog trajanja videosignala pohranjenog u međuspremniku. Prethodna rješenja koristila su trenutnu vrijednost popunjenosti međuspremnika, a ne vrijednost promjene popunjenosti međuspremnika. Dijagram toka CARA algoritma za prilagodljivo strujanje videosignala prikazan je slikom 2.5.

CARA algoritam zasnovan je na novom modelu međuspremnika za reprodukciju videosignala. Međuspremnik za reprodukciju videosignala određen je pomoću tri granične vrijednosti. Agresivnost CARA algoritma odabire se na temelju očekivane popunjenosti međuspremnika.



Slika 2.5. Dijagram toka algoritma CARA.

Ovisno o popunjenosti međuspremnika, odabir odgovarajuće razine kvalitete odnosno reprezentacije vrši se u tri faze:

- procjena: propusnost mreže procjenjuje se mjerenjem vremena potrebnog za preuzimanje segmenta čija se veličina dohvaća iz MPD datoteke,
- očekivanje: procjenjuje se popunjenost međuspremnika korištenjem sljedećeg videosegmenta kako bi se spriječila popunjenost međuspremnika ispod donje granične vrijednosti i iznad gornje granične vrijednosti,
- prilagodba: razina kvalitete za sljedeći videosegment odabire se na temelju popunjenosti međuspremnika.

Broj promjena razine kvalitete u ispitnom zapisu bio je 7 za CARA algoritam, 41 za SARA algoritam i 38 za algoritam koji u obzir uzima samo popunjenost međuspremnika [41].

CARA algoritam stabilniji je u promjenjivim mrežnim uvjetima i zbog manje promjena razine kvalitete ima stabilniju vrijednosti kvalitete videosignala u usporedbi sa SARA algoritmom i algoritmom koji u obzir uzima samo popunjenost međuspremnika.

2.2. Parametri kvalitete korisničkog iskustva u prilagodljivom videostrujanju

Kao što se moglo vidjeti iz prethodno opisanih ABR algoritama za prilagodljivo videostrujanje, većina algoritama objavljenih u zadnjih nekoliko godina ima za cilj osigurati najvišu moguću kvalitetu korisničkog iskustva. Kako bi se provjerila i dokazala poboljšanja u predloženim algoritmima za prilagodljivo videostrujanje, uvijek je potrebno ispitati kvalitetu rezultirajućih videosignala. Specifikacija kvalitete usluge (engl. *Quality of Service* - QoS) obično ovisi o vrsti aplikacije čiji se parametri analiziraju i povezani su s tehničkim aspektima aplikacije.

Kvaliteta usluge dugi se niz godina koristila za kvantificiranje kvalitete u multimedijskim uslugama i bila u fokusu istraživanja u području mrežnih komunikacija. Međutim postavilo se pitanje zadovoljavaju li tehnički parametri mreže potrebe krajnjih korisnika s obzirom da QoS ne uzima u obzir subjektivnost korisnika.

Istraživači grupacije Human-Computer Interaction - HCI prvi su istaknuli da kvaliteta korisničkog iskustva uzima u obzir emocije, odnose, kontekst i očekivanja [42]. ITU-T definira QoE kao subjektivno prihvaćanje usluge od strane korisnika i podrazumijeva da se mjerenje QoE vrši kroz subjektivne eksperimente [43]. QoE je također definiran kao mjera zadovoljstva korisnika s pruženom uslugom [44] koja se razlikuje od subjektivnih metoda za ocjenu kvalitete videosignala (engl. *Video Quality Assessment* - VQA) koje su usredotočene na predviđanje reakcija korisnika na vidljiva izobličenja. No, subjektivni eksperimenti predstavljaju najtočniju metodu za procjenu QoE. U dostupnoj je literaturi [45] također navedeno da je QoE multidisciplinarno područje temeljeno na inženjerstvu, kognitivnoj znanosti, ekonomiji i socijalnoj psihologiji. Na QoE utječu različiti čimbenici kao što su ljudski čimbenici uključuju korisnikove preferencije, različite osjetilne i kognitivne procese. Zatim tu su i čimbenici konteksta koji uključuju ekonomske i socijalne aspekte te vrijeme i prostor u kojem se usluga videostrujanja koristi. Zadnjoj skupini čimbenika pripadaju različita programska i sklopovska ograničenja elektroničkih uređaja [46].

Svi koraci obrade od stvarnog snimanja videosignala, obrade, kodiranja, kompresije, prijenosa, dekodiranja pa do pružanja reprodukcije videosignala imaju jak i izravan utjecaj na ono što korisnik vidi.

Prilagodljivo videostrujanje treba pružiti najbolju ravnotežu između QoE i mogućnosti neprekidnog strujanja videosignala [27]. Kako bi se osigurala najviša moguća razina QoE prilikom

razvoja i ispitivanja sustava za prilagodljivo strujanje potrebno je uzeti u obzir parametre koji imaju najveći utjecaj na kvalitetu korisničkog iskustva:

- Prebacivanje razine kvalitete (engl. *switching*)
- Početno kašnjenje (engl. *initial delay*)
- Zastoji u reprodukciji (engl. *stalling*)
- Prosječna razina kvalitete (engl. *mean quality level*)

Utjecaj broja i dubine prebacivanja razina kvalitete na QoE posebno je važan za sustave zasnovane na MPEG DASH normi te pogrešne odluke u odabiru razine kvalitete mogu imati veliki utjecaj na kvalitetu korisničkog iskustva. Dokazano je da korisnici reagiraju negativno na bilo koje ponašanje sustava kada se prividno daje bolja usluga drugom korisniku, osim ako nije dano privatljivo obrazloženje. To na primjer može biti prijelaz na nižu razinu kvalitete signala, česta prebacivanja razine kvalitete ili razdoblja kada je prijenosna brzina u nekoj sjednici ispod određene razine [47]. Također, dokazano je da ubacivanje srednje razine kvalitete u slučaju snižavanja kvalitete signala povoljnije za percipiranu kvalitetu, u odnosu na prebacivanje izravno do razine ciljne kvalitete bez dodatne međurazine. U slučaju kada su prilikom smanjivanja razine kvalitete dodane međurazine, utjecaj prebacivanja razina kvalitete na kvalitetu korisničkog iskustva bio je minimalan [31]. Ovi eksperimenti pokazuju da je bolje imati stabilan prijenos, ali niže razine kvalitete nego imati prijenos s velikim brojem prebacivanja razine kvalitete i velikom dubinom prebacivanja razine kvalitete, iako se u prosjeku ostvaruje viša razina kvalitete. Također je utvrđeno da smanjenje kvalitete videosignala više utječe na kvalitetu korisničkog iskustva nego povećanje kvalitete videosignala [48].

Osim broja i dubine prebacivanja razina kvalitete te naravno ostvarene prosječne razine kvalitete, značajan utjecaj na QoE u prilagodljivom videostrujanju imaju i početno kašnjenje i zastoji koji se događaju prilikom prikazivanja videosignala zbog nedovoljne popunjenosti međuspremnika.

Duljina početnog kašnjenja ovisi o postavkama kodera i dostupnoj propusnosti u promatranoj mreži. U sustavima za prilagodljivo videostrujanje, početno kašnjenje je uvijek prisutno i opisuje se kao vrijeme potrebno za preuzimanje dovoljne količine podataka koji trebaju biti preneseni prije dekodiranja i početka prikazivanja videosignala kako bi se smanjila učestalost budućih zastoja. Sama duljina početnog kašnjenja je tako obično veća od minimalne duljine potrebne za punjenje međuspremnika kako bi se smanjila vjerojatnosti pojave kasnijih zastoja u prikazivanju videosignala koji se mogu pojaviti zbog manjih promjena u dostupnoj propusnosti.

Algoritmi za prilagodljivo videostrujanje su zaduženi za uspostavljanje ravnoteže jer početno kašnjenje koje, ako je predugo, može smanjiti kvalitetu korisničkog iskustva, no u isto vrijeme početno kašnjenja utječe na početak upravljanja razinama dostupnih prijenosnih brzina videosignala. Također utjecaj početnih kašnjenja na percipiranu kvalitetu ovisi samo o njegovoj duljini, ali ne i o konačnom trajanju videosignala. Međutim bitno je istaknuti da 90 % korisnika smatra da veće početno kašnjenje manje utječe na kvalitetu usluge nego kasniji zastoji u reprodukciji [49].

Zastoji koji se događaju prilikom reprodukcije videosignala zbog nedovoljne popunjenosti međuspremnika značajno utječu na kvalitetu korisničkog iskustva. Nedovoljna popunjenost međuspremnika znači da se međuspremnik u potpunosti ispraznio ili je popunjenost međuspremnika pala ispod donje granične vrijednosti određene algoritmom za prilagodljivo videostrujanje. Zastoji se u pravilu javljaju kada je dostupna propusnost manja od prijenosne brzine videosignala. U slučaju kada više nema dostupnih videosegmenata u međuspremniku, prikazivanje videosignala se prekida sve dok se u međuspremnik ponovno ne učita određenu količina videosegmenata. S obzirom da kratki zastoji u prikazivanju videosignala ozbiljno smanjuju kvalitetu korisničkog iskustva, sve usluge koje se koriste za prijenos videosignala trebale bi izbjegavati zastoje kad god je to moguće.

Osnovni HTTP prijenos videosignala uspostavlja ravnotežu između veličine međuspremnika i trajanja zastoja, no ne može reagirati na nagle promjene u uvjetima u mreži. Prednost sustava za prilagodljivo videostrujanje u odnosu na osnovni HTTP prijenos videosignala je upravo u tome što sustavi koji koriste prilagodljivi HTTP prijenos videosignala imaju mogućnost uskladiti isporuku videosignala s trenutnim uvjetima u mreži čime se smanjuje pojava zastoja. Iz dostupnih istraživanja može se zaključiti da postoji utjecaj na kvalitetu korisničkog iskustva u ovisnosti o mjestu zastoja te kako određenom broju korisnika više smetaju zastoji na početku i pri kraju reprodukcije videosignala [38]. No, utjecaj samog mjesta nije toliko značajan u usporedbi s brojem i trajanjem zastoja. Povećano trajanje zastoja znatno smanjuje kvalitetu korisničkog iskustva. Također korisnicima je jedan duži zastoj prihvatljiviji od češćih kraćih zastoja [50]. Iz dostupnih istraživanja može se zaključiti i da je korisnicima prihvatljivije prijeći na nižu kvalitetu videosignala, pa time imati i prosječno nižu razinu kvalitete nego imati prekide u prikazivanju videosignala [51].

Iako je poznato koji čimbenici imaju najveći utjecaj na kvalitetu korisničkog iskustva i na koji način, još uvijek postoji prostor za unapređenje učinkovitosti postojećih algoritama za prilagodljivo videostrujanje koji uzimaju u obzir parametre koji utječu na QoE korisnika.

Napredak u razvoju algoritama za prilagodljivo videostrujanje prvenstveno se zasniva na razvoju novih metoda i metrika za prikupljanje i analizu parametara koji utječu na kvalitetu korisničkog iskustva.

Primjer metode u kojoj se korisničke aplikacije DASH sustava ne oslanjaju samo na lokalnu logiku prilagodbe i koja poboljšava ukupni QoE među svim korisnicima DASH-a, istovremeno umanjujući negativni utjecaj privremenih promjena kvalitete videosignala opisana je u [52]. Predložena metoda se temelji na dvije objektivne funkcije: funkciji koja maksimizira ukupni prosječni QoE među DASH korisnicima i funkciji koja minimizira negativni utjecaj prebacivanja razina kvalitete odnosno promjene između različitih reprezentacija tijekom prikazivanja videosignala.

Metoda koja uzima u obzir prebacivanje prostorne i vremenske rezolucije koji se događaju tijekom videostrujanja, vremenske oznake zastoja i njihove duljine, broj prebacivanja između različitih reprezentacija, početno kašnjenje te popunjenost međuspremnika opisana je u [53]. Predložena metoda modelirana je na temelju subjektivnih ispitivanja procjene kvalitete videosignala i može se koristiti za poboljšanje izvedbe algoritama za prilagodljivo videostrujanje kao modul u sustavima zasnovanim na MPEG DASH normi te je kompatibilan s trenutno dostupnim komercijalnim aplikacijama pružatelja usluge videostrujanja.

Iz mjerenja provedenih u svrhu ispitivanja predložene metode, ponovno je zaključeno da prebacivanje između dvije susjedne razine kvalitete odnosno reprezentacije manje utječe na vizualnu pozornost korisnika nego prebacivanje između reprezentacija koje su udaljene za više od jednog koraka. Također, prebacivanje između videosignala s različitim prostornim rezolucijama ima veći negativni učinak na QoE korisnika u odnosu na prebacivanje između videosignala s različitim vremenskim rezolucijama.

2.2.1. Usporedba ABR algoritama za prilagodljivo videostrujanje

Postoji nekoliko dostupnih istraživanja koja su analizirala algoritme za prilagodljivo videostrujanje na temelju različitih parametara. Dva algoritma, PID opisan u [54] i KM opisna u [25], koji uzimaju u obzir povijest propusnosti i popunjenost međuspremnika uspoređena su u istraživanju opisanom u [10] s LIU [29] algoritmom koji je algoritam zasnovan na mrežnoj propusnosti. U ispitnom zapisu koji simulira stabilne mrežne uvjete, PID algoritam ostvaruje bolje

vrijeme odziva u odnosu na druga dva algoritma, ali ima problema s pražnjenjem međuspremnika ispod donje granične razine što za posljedicu ima povećan broj zastoja u prikazivanju videosignala. S druge strane, iako su LIU i KM stabilniji što se tiče popunjenosti međuspremnika i iskorištavanja dostupne propusnosti, oba algoritma imaju duže početno kašnjenje u odnosu na PID algoritam. Prilikom uspoređivanja spomenuta tri algoritma, zaključeno je kako je KM stabilniji i bolje radi u različitim mrežnim uvjetima u usporedbi s LIU i PID algoritmima.

U istraživanju opisanom u [55] uspoređeni su algoritmi za prilagodljivo videostrujanje zasnovani na QoE s osnovnim algoritmima koji odluku o odabiru sljedeće razine kvalitete donose na temelju popunjenosti međuspremnika i dostupne propusnosti. Novije vrste algoritama koji u obzir uzimaju dostupnu propusnost razmatraju QoE kroz primjenu matematičkih modela za predviđanje uvjeta u mreži jer osnovne verzije koje u obzir uzimaju dostupnu propusnost nisu dovoljno robusne i ne mogu predvidjeti nagle promjene stanja u mreži. Istraživanjem je pokazano kako hibridni modeli postižu najbolje rezultate u pogledu QoE u promjenjivim mrežnim uvjetima jer odluku o sljedećoj reprezentaciji donose uz pomoć razvijenog okvira za upravljanje. Međutim, još uvijek ima prostora za poboljšanje jer im je potrebna velika računalna snaga za obradu prikupljenih podataka te nije izgledno da će imati komercijalnu upotrebu. Slijedom [55], u [56] je istaknuto da u usporedbi s algoritmima koji u obzir uzimaju samo dostupnu propusnost i algoritmima koji u obzir uzimaju popunjenost međuspremnika, algoritmi koji uzimaju u obzir popunjenost međuspremnika postižu bolji QoE, osim u slučaju usluga za strujanje videosignala uživo gdje je donja granična razina popunjenosti međuspremnika postavljena niže u odnosu na druge usluge za videostrujanje. Također, dva algoritma za prilagodljivo videostrujanje (jedan koji u obzir uzimaju dostupnu propusnost i jedan koji u obzir uzimaju popunjenost međuspremnika) uspoređeni su u [57] pomoću 5G mrežnih ispitnih zapisa. U ovoj konkretnoj primjeni, algoritmi koji u obzir uzimaju dostupnu propusnost postižu bolje rezultate u stabilnim mrežnim uvjetima, ali imaju duže početno kašnjenje. S druge strane, algoritmi koji u obzir uzimaju popunjenost međuspremnika imaju kraće početno kašnjenje, ali ne postižu maksimalan potencijal dostupnih reprezentacija uzimajući u obzir mrežne uvjete. Ipak, u slučajevima kada postoje značajniji periodi smanjene propusnosti u mreži, algoritmi koji u obzir uzimaju dostupnu propusnost također ne postižu maksimalan potencijal dostupnih reprezentacija, ali i dalje ostvaruju zadovoljavajuće rezultate u slučaju promjenjivih mrežnih uvjeta.

Kako bi se dao bolji uvid u način rada ABR algoritama, u okviru istraživanja provedenog za ovaj doktorski rad, napravljena je usporedba tri ABR algoritama koja se najčešće koriste u dostupnoj literaturi na osnovu parametara koji utječu na kvalitetu korisničkog iskustva. LIU

algoritam, koji odluku o sljedećoj reprezentaciji donosi uzimajući u obzir samo dostupnu propusnost, uspoređen je s dva hibridna algoritma, SARA i CARA, koji u obzir uzimaju popunjenost međuspremnika, dostupnu propusnost i veličinu segmenta. Algoritmi su uspoređeni na osnovu broja i dubine prebacivanja (promjene) razina kvalitete, prosječne kvalitete videosegmenata iskazane preko objektivne ocjene kvalitete te postignute prosječne kodne prijenosne brzine. Cilj ovog dijela istraživanja bio je utvrditi ponašanje ABR algoritama u različitim mrežnim uvjetima, za videosignale s različitom razinom aktivnosti.

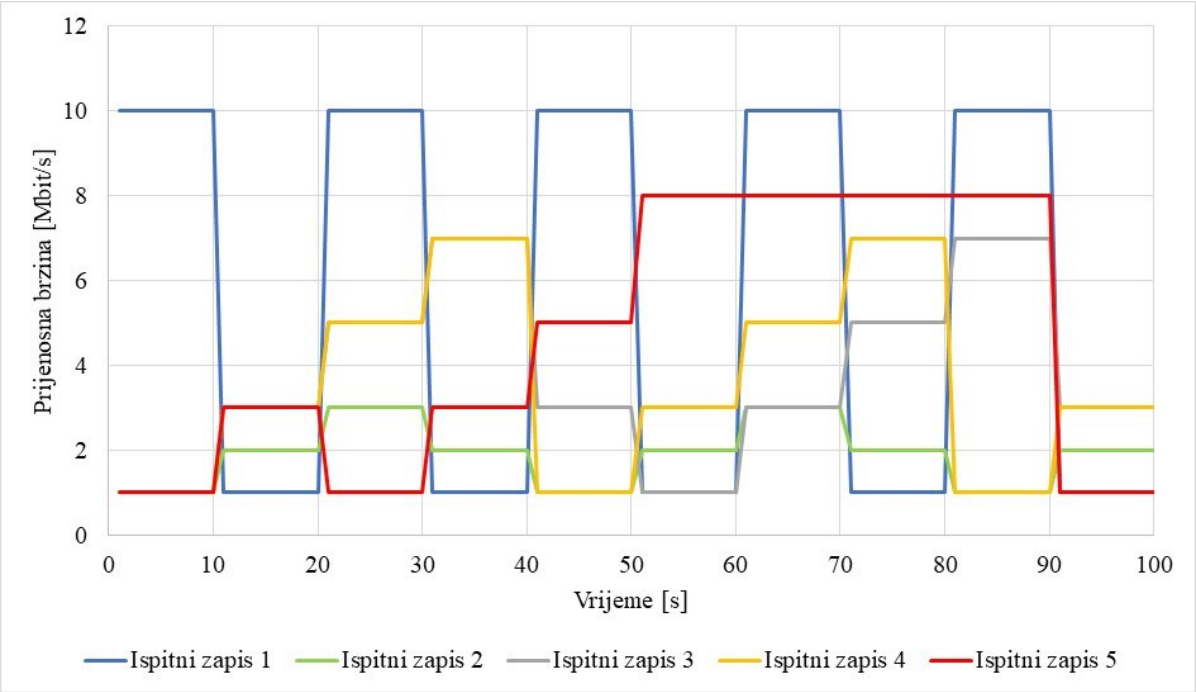
Algoritmi su ispitani uz pomoć pet različitih mrežnih ispitnih zapisa, koristeći tri različita videosignala, iz dostupne baze videosignala, pripremljenih za korištenje u sustavima zasnovanim na MPEG DASH normi [4]. S obzirom na istraživanja opisana u [4] potrebno je istaknuti da segmenti kraćeg trajanja mogu prouzročiti dulje trajanje sinkronizacije s obzirom na broj zahtjeva, što rezultira većim brojem prebacivanja razina kvalitete i smanjenom učinkovitošću kodiranja. S druge strane, korisnik ne može dovoljno učinkovito prilagoditi videostrujanje u slučaju velikih promjena u mrežnim uvjetima kada se koriste segmenti duljeg trajanja. Da bi se uskladili ovi zahtjevi, u ispitivanju je korišteno trajanje segmenta od šest sekundi. Koristila su se tri videosignala različite prostorne i vremenske aktivnosti: *Elephants Dream* (ED) [58], *Big Buck Bunny* (BBB) [59] i *Of Forest and Men* (OFAM) [60] (prostorna i vremenska aktivnost videosadržaja detaljno je obrađena u trećem poglavlju). Sva tri videosignala dostupna su u YUV formatu YUV420p s prostornom rezolucijom 1920 x 1080 elemenata slike i vremenskom rezolucijom 25 slika u sekundi (engl. *frames per second* - fps).

Korištena baza videosignala pripremljenih za korištenje u sustavima zasnovanim na MPEG DASH normi sastoji se od segmenata videosignala kodiranih na različitim prostornim rezolucijama i kodnim brzinama, ali s jednakim brojem slika u sekundi. BBB i ED kodirani su u 20 različitih razina kvalitete (20 reprezentacija): tri za prostornu rezoluciju 320x240, pet za prostornu rezoluciju 480x360, dvije za prostornu rezoluciju 854x480, četiri za prostornu rezoluciju 1280x720 i šest za prostornu rezoluciju 1920x1080 SR pri kodnim brzinama od 45 kbit/s do 3,9 Mbit/s za BBB i 46 kbit/s do 4,1 Mbit/s za ED. OFAM je kodiran u 19 različitih razina kvalitete: tri za prostornu rezoluciju 320x240, četiri za prostornu rezoluciju 480x360, tri za prostornu rezoluciju 854x480, devet za prostornu rezoluciju 1280x720 i šest za prostornu rezoluciju 1920x1080 pri kodnim brzinama od 47 kbit/s do 3,7 Mbit/s.

Sustav korišten za ispitivanje opisan je u [14] i ima korisničku i poslužiteljsku stranu aplikacije. Korisnička se strana sastoji od modula za čitanje MPD datoteke i spremanje dohvaćenih podataka u odgovarajuće strukture, logičkog modula prilagodbe koji sadrži ABR algoritam, modula za preuzimanje segmenata, međuspremnika koji se koristi za pohranu preuzetih segmenata i modula koji se koristi za stvaranje izlazne datoteke. Sustav je napisan pomoću programskog jezika C++ i nadograđen je u odnosu na dostupnu verziju sa SARA i CARA algoritmima kao zasebnim programskim modulima. Maksimalna razina međuspremnika postavljena je na 40 sekundi. Za potrebe ovog ispitivanja dva su računala korištena kao korisnik i poslužitelj. Mrežni ispitni zapisi postavljeni su pomoću programa za ograničavanje mrežne propusnosti Wonder Shaper [61] i pet *bash* skripti.

Nakon preuzimanja MPD datoteke, datoteka se raščlanjuje tako da korisnik može dobiti sve potrebne informacije. Modul za preuzimanje segmenata mjeri raspoloživu propusnost i u slučaju promjene mrežnih uvjeta aktivira se logički modul za prilagodbu uvjetima u mreži. Logički modul za prilagodbu uvjetima u mreži odlučuje je li potrebno napraviti prebacivanje na nižu ili višu razinu kvalitete ili ostati na trenutnoj.

Pet različitih mrežnih ispitnih zapisa korištenih za simuliranje promjenjivih mrežnih uvjeta prikazano je slikom 2.6.



Slika 2.6. Krivulje promjene prijenosne brzine u mrežnim zapisima korištenim u ispitivanju

Ograničenje dostupne propusnosti mijenjalo se svakih 10 sekundi i slijed se izvodio u petlji dok se nije preuzeo cijeli videosignal. Zapis 2 jedini je zapis koji ima najmanju maksimalnu vrijednost dostupne propusnosti: 3000 kbit/s.

Usporedba LIU, CARA i SARA algoritama napravljena je na temelju nekoliko veličina koje začajno utječu na QoE kod videostrujanja. Izračunate su vrijednosti vršne vrijednosti odnosa signala i šuma (engl. *Peak Signal to Noise Ratio* – PSNR) za kodirane videosignale [62], broj i dubina prebacivanja razina kvalitete te srednja postignuta prijenosna brzina i srednja standardna derivacija posignute prijenosne brzine. Vrijednosti PSNR izračunate su za Y komponentu za videosignale u prostornoj rezoluciji 1080x1920 elemenata slike, što odgovara rezoluciji referentnog videosignala kao i onog koji se prikazuje korisniku (dijelovi videosignala koji se prenose s manjom prostornom rezolucijom, prije prikazivanja se interpolacijom pretvaraju u signal originalne rezolucije). Iako PSNR ima ograničenu korelaciju sa subjektivnom ocjenom kvalitete videosignala, ovaj mjerni podatak daje vrijedne informacije za usporedbu različitih algoritama. Rezultati ocjene pomoću PSNR objektivne metode za svih pet ispitnih mrežnih zapisa prikazani su u tablici 2.1. Rezultati pokazuju da videosignal s najvišim vrijednostima prostorne i vremenske aktivnosti (OFAM) ima najniže vrijednosti PSNR-a za sve ispitne slučajeve, iz čega se može zaključiti da složeniji videosignali u danim mrežnim uvjetima imaju nižu prosječnu razinu kvalitete. Rezultati prikazani u tablici 2.2. pokazuju da većina videosignala ima najviše vrijednosti PSNR-a s CARA algoritmom, osim u slučaju kada su i prostorna i vremenska aktivnost (OFAM) visoke. U tim uvjetima strategija adaptacije SARA algoritma osigurala je najbolju kvalitetu videosignala prema rezultatima PSNR-a. Jedina iznimka je ispitni mrežni zapis 1, gdje CARA bolje iskorištava razdoblja visoke dostupne propusnosti (10 Mbit/s).

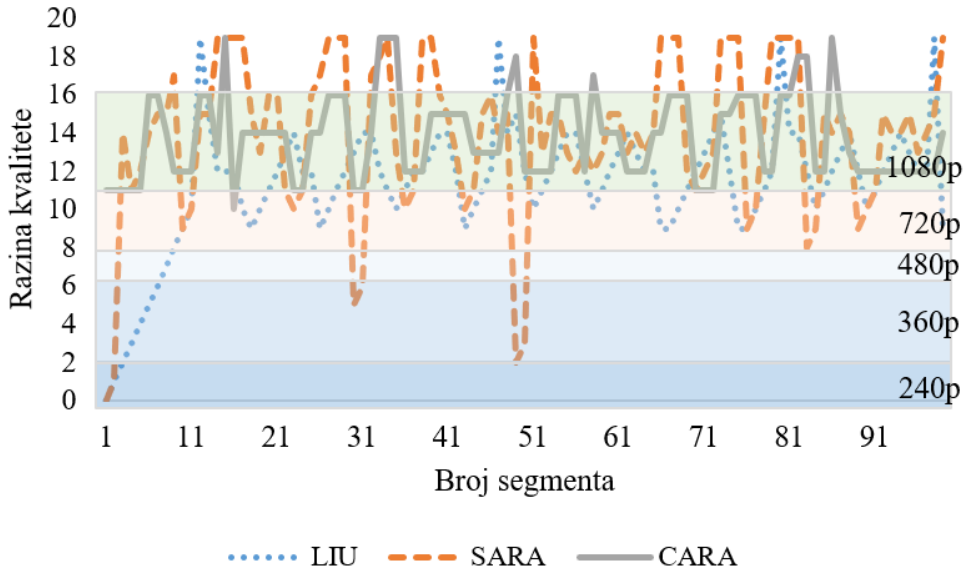
Nadalje, naglo prebacivanje između razina kvalitete (reprezentacija) za više od jednog koraka ima veći utjecaj na QoE nego prebacivanje između razina kvalitete za samo jedan korak. Razine kvalitete (odabrane reprezentacije) za sve segmente videosignala BBB-a za mrežne ispitne zapise 2 i 4 prikazane su na slikama 2.7 i 2.8. SARA algoritam ima nižu razinu kvalitete u prvih nekoliko sekundi u odnosu na CARA algoritam zbog svoje faze brzog pokretanja čime ostvaruje kraće početno kašnjenje, ali u ostalim fazama ima najvišu srednju razinu kvalitete.

Ipak, može se vidjeti da je SARA algoritam osjetljiv na promjene mrežnih uvjeta kada je prosječna dostupna propusnost manja od 3000 kbit/s, kao što je u mrežnom ispitnom zapisu 2. CARA ima najmanje promjena kvalitete u mrežnom ispitnom zapisu 2 i ima najbolju kvalitetu videosignala na početku reprodukcije u svim mrežnim ispitnim zapisima. Nadalje, CARA

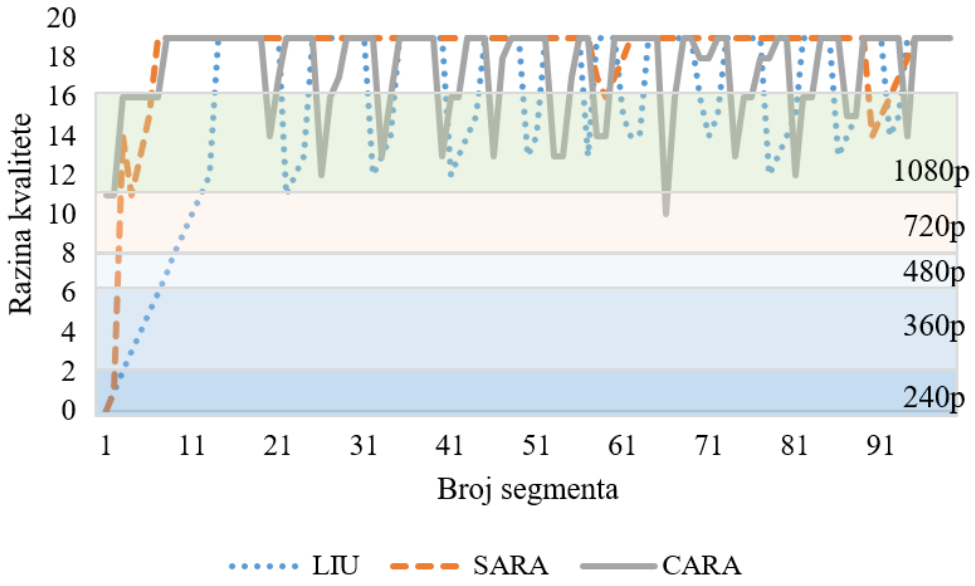
ostvaruje najmanji broj prebacivanja razina kvalitete na nižu razinu (*Sdown*). Iako SARA u većini mrežnih ispitnih zapisa ima najvišu srednju razinu kvalitete, vrijednosti PSNR-a su veće za CARA algoritam zbog činjenice da SARA ima vrlo nisku razinu kvalitete u početku, kao i povremena izraženija smanjenja prostorne rezolucije nakon toga. LIU je stabilniji od SARA algoritma, ali ima veću vrijednost početnog kašnjenja i sveukupno nižu prosječnu razinu kvalitete.

Tablica 2.2. Rezultati ocjene pomoću PSNR [dB] objektivne metrike za svih pet ispitnih mrežnih zapisa

	Mrežni ispitni zapis	**1**	**2**	**3**	**4**	**5**	**Prosječna vrijednost PSNR-a**
BBB	LIU	33,35	36,03	36,15	35,92	36,02	38,67
	CARA	34,83	38,95	39,03	38,75	38,28	39,82
	SARA	33,76	32,20	37,87	37,86	36,04	38,50
ED	LIU	35,57	37,39	37,58	36,77	37,48	40,09
	CARA	36,41	39,11	39,12	39,09	38,81	40,32
	SARA	36,17	36,88	37,23	36,86	37,49	40,30
OFAM	LIU	30,66	32,37	32,95	31,87	32,24	33,36
	CARA	30,95	32,85	33,58	33,03	32,81	33,63
	SARA	29,46	33,49	33,65	33,95	32,93	34,08



Slika 2.7. Trend prebacivanja razine kvalitete za BBB videosignal – mrežni ispitni zapis 2



Slika 2.8. Trend prebacivanja razine kvalitete za BBB videosignal – mrežni ispitni zapis 4

Tablica 2.3. prikazuje rezultate koji se odnose na broj prebacivanja na višu razinu reprezentacije (*Sup*) i broj prebacivanja na nižu razinu reprezentacije (*Sdown*). Podaci prikazani u tablici 2.3. predstavljaju zbroj *Sup* i *Sdown*. Iz tablice 2.3. može se vidjeti da LIU algoritam u prosjeku ima najviše prebacivanja razine kvalitete u danim mrežnim uvjetima, dok SARA ima u prosjeku najmanje prebacivanja razine kvalitete. To se događa zbog činjenice da SARA ima četiri faze odlučivanja prilikom odabira reprezentacije sljedećeg segmenta i razvijen je kako bi bio robusniji u usporedbi s druga dva algoritma. CARA postiže slične rezultate kao SARA u većini mrežnih ispitnih zapisa, osim u mrežnim ispitnim zapisima 1 i 2. CARA ostvaruje lošije rezultate kada postoje trenutne promjene između vrlo visokih i vrlo niskih vrijednosti dostupne propusnosti kao u zapisu 1, ali nadmašuje druga dva algoritma kada je dostupna propusnost manja od 3 Mbit/s tijekom cijelog vremena preuzimanja videosignala. To je zbog činjenice da CARA uzima u obzir veličinu segmenta i popunjenost međuspremnika te na početku preuzimanja videosignala agresivnije povećava razinu kvalitete u usporedbi s druga dva algoritma.

Tablica 2.3. Zbroj *Sup* i *Sdown* po mrežnom ispitnom zapisu za sve videosignale

	Mrežni ispitni zapis					
Algoritam	**1**	**2**	**3**	**4**	**5**	**Prosječna vrijednost**
LIU	36,67	81,67	45,00	44,33	42,00	49,93
CARA	40,33	**37,67**	27.33	33,67	25,33	32,87
SARA	**4.67**	67,67	**23,67**	**24,33**	**20,00**	**28.07**

Tablica 2.4. daje rezultate ispitivanja za zbroj vrijednosti Sup i Sdown, ali za različite videosignale. Iz rezultata se vidi da, bez obzira na videosignal, LIU algoritam ima najveći broj prebacivanja razina kvalitete, a SARA algoritam najmanji broj prebacivanja razina kvalitete. Nadalje, može se zaključiti da videosignal s najvišom prostornom aktivnosti ima najviše prebacivanja razina kvalitete zbog najveće veličine segmenta za dano trajanje segmenta od 6 sekundi. BBB koji ima najniže vrijednosti prostorne i vremenske aktivnosti ima najmanji broj prebacivanja razina kvalitete. Iz tablice 2.5 može se vidjeti da iako SARA i CARA imaju sličnu prosječnu vrijednost dubine prebacivanja, SARA i dalje ima veću vrijednost dubine prebacivanja zbog svoje treće faze u kojoj agresivnije prebacuje razinu kvalitete kada je popunjenost međuspremnika između druge i treće granične vrijednosti.

Tablica 2.4. Zbroj *Sup* i *Sdown* po videosignalu za sve mreže ispitne zapise

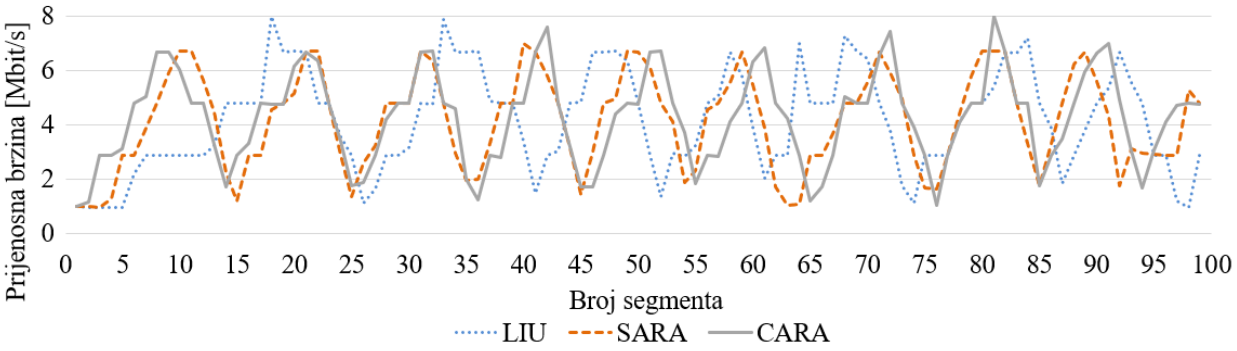
Algoritam	**BBB**	**ED**	**OFAM**
LIU	39,40	58,00	52,40
CARA	27.60	36,20	34,80
SARA	**23.20**	**35,20**	**25.80**

Tablica 2.5. Srednja dubina prebacivanja razina kvalitete

	Mrežni ispitni zapis					
Algoritam	**1**	**2**	**3**	**4**	**5**	**Prosječna vrijednost**
LIU	4,51	1,75	2.73	3.77	2.96	3.15
CARA	3.89	3.38	3,70	3.97	4.28	3.84
SARA	4.73	3.72	4.46	3.24	3.74	**3.98**

Slika 2.9. prikazuje postignute vrijednosti prijenosne brzine za svaki segment BBB videosignala za treći mrežni ispitni zapis. Trenutno postignuta prijenosna brzina približno odgovara kodnoj brzini za zadani segment i implicitno ukazuje na kvalitetu kodiranog videosignala. Vidljivo je da CARA ima brži porast postignute prijenosne brzine u usporedbi s druga dva algoritma na početku razdoblja preuzimanja.

Nakon faze pokretanja, SARA brže reagira na promjene u mreži nego CARA. Također se može vidjeti da LIU algoritam ima najniže postignute vrijednosti prijenosne brzine kroz cijelo razdoblje preuzimanja videosignala, što ukazuje na najnižu kvalitetu videosignala.



Slika 2.9. Postignuta prijenosna brzina za svaki dio videosignala *Big Buck Bunny* za mrežni ispitni zapis 3.

Tablica 2.6. daje srednje vrijednosti postignute prijenosne brzine za svaki algoritam, videosignal i mrežni ispitni zapis. Sve vrijednosti dane su u kbit/s. Na temelju ostvarenih rezultata može se zaključiti da CARA postiže najviše prosječne vrijednosti postignute prijenosne brzine za BBB i ED, ali za OFAM koji ima najveću prostornu i vremensku aktivnost, SARA ima najveću prosječnu postignutu brzinu prijenosa.

Tablica 2.6. Srednja postignuta prijenosna brzina u kbit/s

Videosignal	**Mrežni ispitni zapis**	**1**	**2**	**3**	**4**	**5**	**Prosječna vrijednost**
BBB	LIU	7802	2002	4049	4295	5322	**4694**
	CARA	7060	2137	4164	5409	5478	**4850**
	SARA	7212	1924	4044	4357	5195	**4546**
	Prosj.	**7358**	**2021**	**4086**	**4687**	**5332**	**4697**
ED	LIU	7878	2053	4214	4628	4309	**4616**
	CARA	7137	2056	4215	4269	5491	**4634**
	SARA	7046	2094	4242	4198	5315	**4579**
	Prosj.	**7354**	**2068**	**4224**	**4365**	**5038**	**4610**
OFAM	LIU	7781	1988	4074	4299	5127	**4654**
	CARA	7163	2152	4241	4267	5179	**4600**
	SARA	7090	2105	4457	4211	5491	**4671**
	Prosj.	**7344**	**2082**	**4257**	**4259**	**5266**	**4642**

Kao što se može vidjeti u tablici 2.7. najveća standardna devijacija postignute prijenosne brzine je u slučaju LIU algoritma koji ima najduže početno kašnjenje i manje je otporan na promjene u dostupnoj propusnosti.

Tablica 2.7. Srednja standardna devijacija postignute prijenosne brzine

Videosignal	Mrežni ispitni zapis	1	2	3	4	5	Prosječna vrijednost
BBB	LIU	2.833	871	1.839	1.805	2663	**2.002**
	CARA	3.256	715	1.687	1.919	2,497	**2.015**
	SARA	3,205	575	1.737	1.823	2,493	**1.966**
	Prosj.	**3.098**	**720**	**1.754**	**1.849**	**2,551**	**1.994**
ED	LIU	2.908	843	1.778	2,067	2.899	**2.099**
	CARA	3.243	594	1.759	1.659	2.593	**1.970**
	SARA	3.297	682	1.743	1.814	2.500	**2.007**
	Prosj.	**3.149**	**706**	**1.760**	**1.846**	**2.664**	**2.025**
OFAM	LIU	2.905	674	1.936	1.907	2.765	**2.037**
	CARA	3,313	678	1.763	1.817	2,498	**2.014**
	SARA	3.232	678	1.843	1.856	2,529	**2.028**
	Prosj.	**3.150**	**677**	**1.847**	**1.860**	**2,598**	**2.026**

3. KVALITETA VIDEOSIGNALA

Trenutno velika količina usluga za strujanje videosignala, uključujući društvene medije, koristi objektivne metode procjene kvalitete videa za mjerenje i kontrolu kvalitete videosignala koji se isporučuju krajnjim korisnicima [63-64], no važno je istaknuti da objektivne metode ne mogu uvijek točno opisati kvalitetu korisničkog iskustva.

Mjerenje i optimizacija kvalitete videosignala složen je problem s obzirom na subjektivnost i velik izbor čimbenika koji utječi na kvalitetu korisničkog iskustva. Postoje mnogi čimbenici koji utječu na kvalitetu samog videosignala u procesu obrade, prijenosa i prikazivanja videosignala kao što su: način snimanja videosignala, parametri kodiranja, vrsta i parametri kompresije, prijenosni medij, parametri dekodiranja i dr. Osim navedenih tehničkih parametara koji utječu na vizualnu vjernost videosignala u pogledu nepravilnosti u vremenskoj i prostornoj strukturi videosignala koji se pojavljuju u različitim koracima obrade videosignala, gubitak kvalitete videosignala može se promatrati i kroz prizmu samog korisnika koji je također pod utjecajem drugih čimbenika koji nisu tehničke prirode, kao što su emocije, iskustvo, kontekst uporabe i dr. [65].

Neki od brojnih čimbenika koji utječu na kvalitetu korisničkog iskustva su:

- Uvjeti gledanja videosignala (udaljenost, rasvjeta),
- Vrsta zaslona na kojem se prikazuje videosignal (CRT, LCD, LED, itd.),
- Svojstva i parametri zaslona na kojem se prikazuje videosignal (veličina, maksimalna prostorna rezolucija, svjetlina, kontrast, vrijeme odaziva, broj boja),
- Interakcija s uslugom i uređajem koji se koristi za prikazivanje videosignala (vrsta i optimiziranost Internet aplikacije, elektronski programski vodič (engl. *Electronic Program Guide* - EPG)),
- Kvaliteta i sinkronizacija pratećeg zvuka,
- Iskustvo gledatelja (npr. nakon što korisnik vidi kako izgleda videosignal u 1080 x 1920 ili višoj prostornoj rezoluciji, primijetit će promjenu na nižu prostornu rezoluciju što će utjecati na kvalitetu korisničkog iskustva). Istraživanja su pokazala korisnici videosignale s većim brojem boja i oštrinom slike s visokim kontrastom smatraju više privlačnim u odnosu na mutne slike s niskim kontrastom i svjetlinom.
- Pojedinačni interesi gledatelja u smislu sadržaja videosignala određuju razinu pozornosti [65].

3.1. Prostorna i vremenska informacija videosadržaja

S obzirom da na kvalitetu kodiranog videosignala u videostrujanju značajno utječu parametri kodiranja i segmentacije videosignala, njihovo je istraživanje započeto analizom složenosti kodiranja videosignala koje ovisi o prostornoj i vremenskoj aktivnosti videosadržaja. Prostorno-vremenska aktivnost videosadržaja može se odrediti pomoću parametara prostorne (engl. *Temporal Information* - TI) i vremenske (engl. *Spatial Information* - SI) informacije kako je dano izrazima (3-1) i (3-2):

$$SI_i(t) = \overline{std[Sobel(F_i(x,y,t))]} \tag{3-1}$$

$$TI_i(t) = \overline{std[F_i(x,y,t) - F_i(x,y,t-1)]} \tag{3-2}$$

gdje je *std* standardna devijacija, a *Sobel* predstavlja Sobelov operator. F_i predstavlja i-ti dio slike u promatranom videosignalu. U istraživanju predstavljenom u ovom doktorskom radu, SI i TI određeni su prema izrazima (3-1) i (3-2) kao srednje vrijednosti SI i TI, a ne kao maksimalne vrijednosti kako je definirano u preporuci ITU-T P.910 [66]. Naime, maksimalne vrijednosti ovih parametara mogu biti puno veće od prosječnih vrijednosti te se mogu pojaviti u vrlo kratkom djeliću videosignala što neće značajno utjecati na prosječnu kvalitetu kodiranog signala. Stoga je prosjek ovih vrijednosti kroz cijeli videosignal bolji izbor za istraživanje vezano za prilagodljivo videostrujanje.

Ideja provedenog ispitivanja bila je analizirati kako prostorna i vremenska aktivnost videosignala utječu na njegovu kvalitetu na različitim prostornim rezolucijama i prijenosnim brzinama.

Izvorni videosignali korišteni za ispitivanje preuzeti su iz baze videosignala opisane u [67] koja osim izvornih videosignala sadrži i videosignale kodirane pomoću skalabilnog kodiranja videosignala (engl. *Scalable Video Coding* – SVC) za MPEG DASH sustave.

Iz dostupne baze videosignala, za preliminarno ispitivanje utjecaja videosadržaja na kvalitetu kodiranog signala, odabrana su četiri videosignala s različitim prostornim i vremenskim aktivnostima: *Blue Sky* (BS), *Station2* (S2), *Pedestrian Area* (PA) i *Life* (LF). Sva četiri videosignala dostupna su u neobrađenom YUV formatu (YUV420p, prostorne rezolucije 1920x1080 elementa slike, vremenske rezolucije 25 slika po sekundi). Sva četiri videosignala kodirana su H.264 koderom. Prilikom kodiranja korištene su sljedeće prostorne rezolucije: 640 x 360, 1280 x 720 i 1920 x 1080 elementa slike. Sve kombinacije prostorne rezolucije i kodnih brzina korištenih u svrhu ispitivanja navedene su u tablici 3.1. Osim ciljanih kodnih brzina, u tablici su

navedene i ostvarene prijenosne brzine za svaki videosignal. Ciljane kodne brzine odabrane su prema preporuci iz dostupnih istraživanja i pružatelja usluga videostrujanja (YouTube) [67]. Korišteni parametri kodiranja videosignala prikazani su u tablici 3.2.

Tablica 3.1. Prostorne rezolucije, kodne i ostvarene prijenosne brzine videosignala korištenih u ispitivanju

Prostorna rezolucija	**H.264 kodna brzina [kbit/s]**	**S2 [kbit/s]**	**PA [kbit/s]**	**LF [kbit/s]**	**BS [kbit/s]**
640 x 360	600	690	713	662	794
640 x 360	900	947	994	960	1088
640 x 360	1250	1243	1323	1305	1429
640 x 360	1600	1554	1659	1643	1771
640 x 360	2500	2291	1974	2452	2634
1280 x 720	1500	1552	1604	1557	1669
1280 x 720	2500	2483	2578	2552	2648
1280 x 720	4000	3703	4056	4041	4121
1280 x 720	6000	4508	5269	5800	6007
1920 x 1080	2500	2526	2592	2552	4128
1920 x 1080	4000	4926	4071	4043	4107
1920 x 1080	5000	5684	5061	5040	5087
1920 x 1080	6000	6943	6040	6032	6072
1920 x 1080	8000		8021	7956	7903

Tablica 3.2. H.264 parametri kodiranja

Naziv parametra	**Vrijednost**
Strategija kodiranja	promjenjiva prijenosna brzina, kodiranje u dva prolaza
Profil	Visoki
Vrsta kodiranja	Kontekstualno prilagodljivo binarno aritmetičko kodiranje (engl. *Context-adaptive binary arithmetic coding* – CABAC)
Razina	4.0
peak rate	1080p Superbit
Sažimanje krivulje kvantizatora	0,9
Minimum kvantizacije	3

Vrijednosti SI i TI izračunate su kao srednje vrijednosti za Y komponentu videosignala. Vrijednosti SI i TI za sve kodirane varijante videosignala za sva četiri različita sadržaja prikazani su u tablici 3.3. Rezultati pokazuju da videosignali S2 i PA imaju najniže vrijednosti SI i TI, s tim da imaju slične vrijednosti SI, ali PA ima duplo veći TI od S2. Videosignal BS ima najveći SI i TI. Kako se rezolucija smanjuje, SI značajno raste, a TI se smanjuje. Na pojedinoj prostornoj rezoluciji, promjene u prijenosnoj brzini ne utječu značajno na SI i TI.

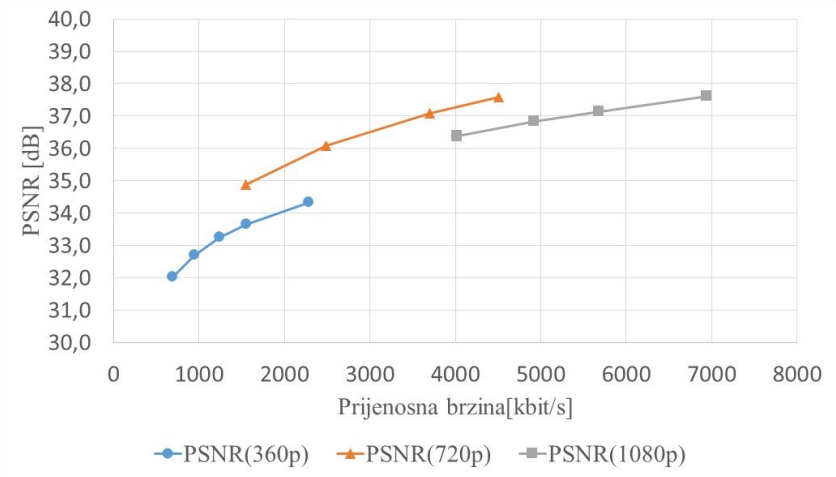
Tablica 3.3. Srednja vrijednost prostorne i vremenske informacije za Y komponentu videosignala

Prostorna rezolucija	**Kodna brzina [Mbit/s]**	**S2**		**PA**		**LF**		**BS**	
		SI	**TI**	**SI**	**TI**	**SI**	**TI**	**SI**	**TI**
1920 x 1080	**2,5**	33.8	7.6	33.8	15.5	55.0	18.6	79.7	33.6
	4	33.8	7.6	33.3	15.5	55.2	18.6	79.6	33.6
	5	33.6	7.5	33.2	15.4	55.2	18.6	79.3	33.5
	6	33.5	7.5	33.0	15.4	55.2	18.6	79.1	33.5
	8	33.4	7.5	32.9	15.4	55.1	18.6	79.0	33.4
1280 x 720	**1,5**	40.4	7.5	41.3	15.5	61.7	18.0	100.0	33.5
	2,5	40.1	7.4	41.3	15.5	61.8	18.0	99.7	33.4
	4	40.0	7.2	41.0	15.4	61.7	17.9	99.4	33.3
	6	39.9	7.2	40.7	15.4	61.6	17.8	99.5	33.2
640 x 360	**0,6**	45.3	6.7	53.1	15.5	75.1	17.0	123.5	31.6
	0,9	45.1	6.6	52.8	15.4	75.1	16.8	123.8	31.5
	1,2	45.1	6.4	52.8	15.3	75.2	16.7	124.0	31.4
	1,6	45.2	6.3	53.0	15.3	75.3	16.7	124.2	31.4
	2,5	45.2	6.1	53.1	15.2	75.6	16.6	124.6	31.2

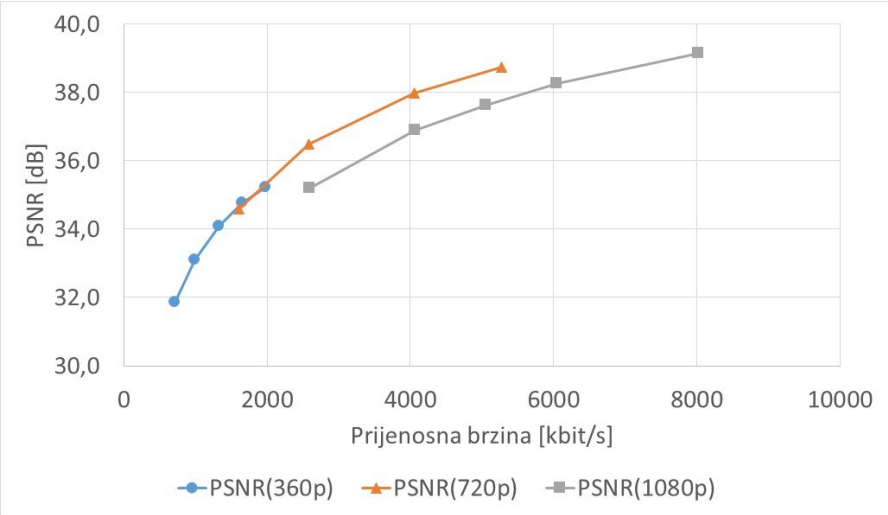
Poznato je da prostorna i vremenska aktivnost utječu na kvalitetu kodiranog videosignala i da smanjenje vremenske i/ili prostorne rezolucije različito utječu na kvalitetu videosignala za videosignale s niskom i visokom aktivnošću. Iz objavljenih istraživanja može se zaključiti da osim uvjeta u mreži i vrsta videosadržaja ima značajan utjecaj na izbor prostorne rezolucije i vremenske rezolucije, a time i na postignutu kvalitetu videosignala [68]. Također, može se zaključiti da je veću

vremensku rezoluciju za videosignale najbolje koristiti kada postoji i dovoljno visoka propusnost u mreži. U mrežama gdje je dostupna mrežna propusnost niska, kvaliteta korisničkog iskustva prvenstveno ovisi o prostornoj rezoluciji. Najučinkovitiji način za poboljšanje kvalitete korisničkog iskustva je poboljšanje odnosa signala i šuma prilikom unutar-okvirnog (engl. *intra-frame*) kodiranja u slučajevima kada se koriste relativno visoke prostorne ili vremenske rezolucije pri malim prijenosnim brzinama. Nadalje, iz dostupne literature se može zaključiti da kada se prenose videosignali s visokom vremenskom aktivnošću kodirane niskim kodnim brzinama, korisnici često daju prednost videosignalima s nižom prostornom rezolucijom [69].

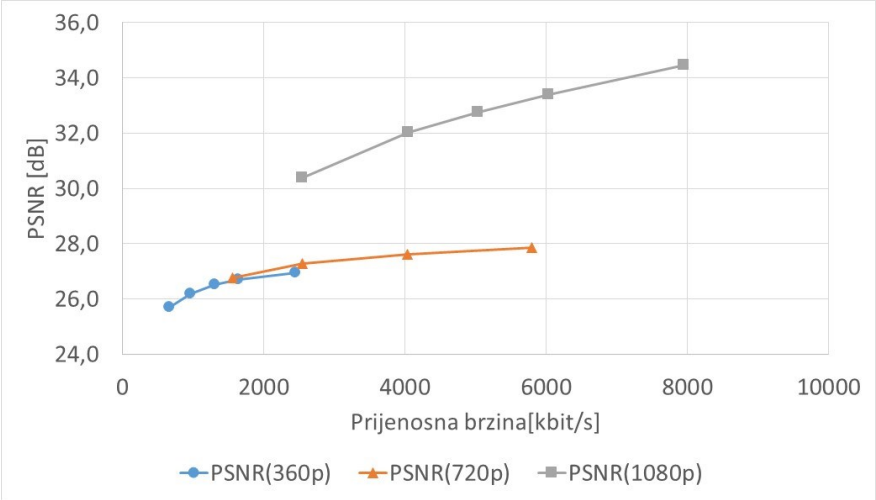
Kako bi se istražili ovi utjecaji, provedena je ocjena kvalitete kodiranih videosignala objektivnim metrikama PSNR i SSIM (engl. *Structural Similariy Index Measure*) [70]. Prije proračuna objektivnih ocjena kvalitete, videosignali kodirani na prostornu rezoluciju manju od prostorne rezolucije izvornog videosignala (1920x1080), skalirani su na izvornu prostornu rezoluciju pomoću FFmpeg-a [71]. Vrijednosti PSNR-a i SSIM-a izračunate su kao srednja vrijednost za Y komponentu za prijenosne brzine navedene u tablici 3.3. Rezultati proračuna PSNR-a prikazani su slikama 3.1. do 3.4. Kako bi se analiziralo hoće li biti razlike u rezultatima ako se koristi neka druga objektivna metoda za ocjenu kvalitete, izračunate su i vrijednosti SSIM-a po istoj metodologiji kao i za PSNR. Rezultati proračuna SSIM-a prikazani su na slikama 3.5. - 3.8. Vrijednosti PSNR i SSIM za videosignal S2 (slike 3.1. i 3.5.) pokazuju da obje objektivne metode za ocjenu kvalitete videosignala vode do istih zaključaka. Isto se odnosi na ostale slike koje pokazuju PSNR i SSIM rezultate za videosignale PA, LF i BS. Rezultati pokazuju da videosignali s najmanjim SI, odnosno S2 i PA imaju najviše PSNR vrijednosti (slika 3.1. i slika 3.2.) i da se vrijednosti PSNR smanjuju kako videosignali imaju viši parametar SI (slika 3.3. i slika 3.4.).



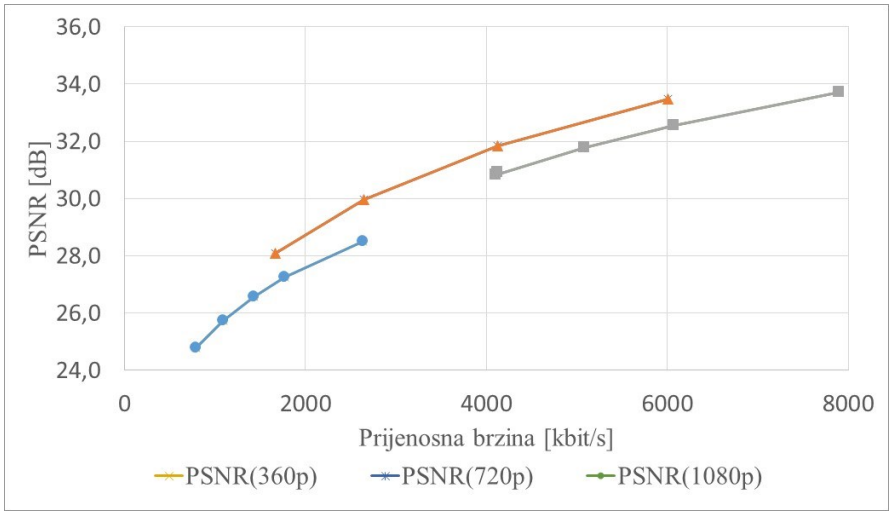
Slika 3.1. Grafički prikaz ovisnosti PSNR-a i prijenosne brzine za *Station2* (S2) videosignal



Slika 3.2. Grafički prikaz ovisnosti PSNR-a i prijenosne brzine za *Pedestrian Area* (PA) videosignal



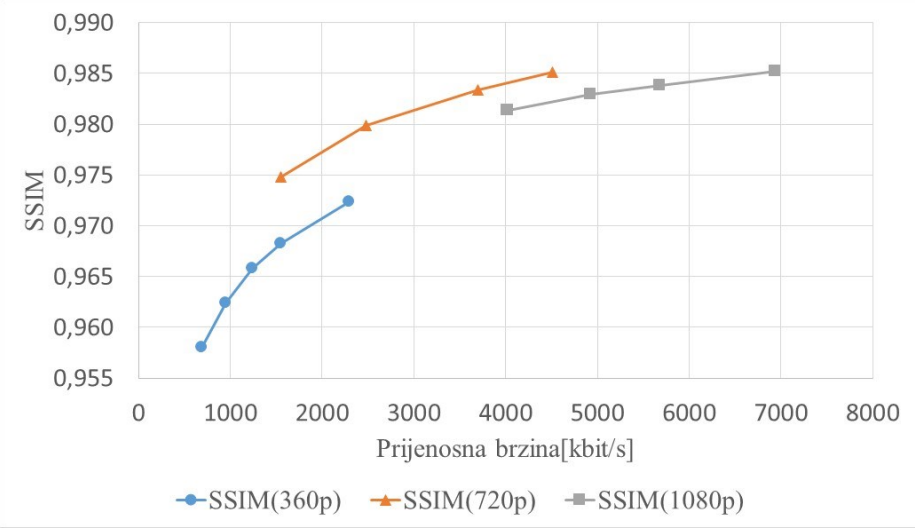
Slika 3.3. Grafički prikaz ovisnosti PSNR-a i prijenosne brzine za *Life* (LF) videosignal



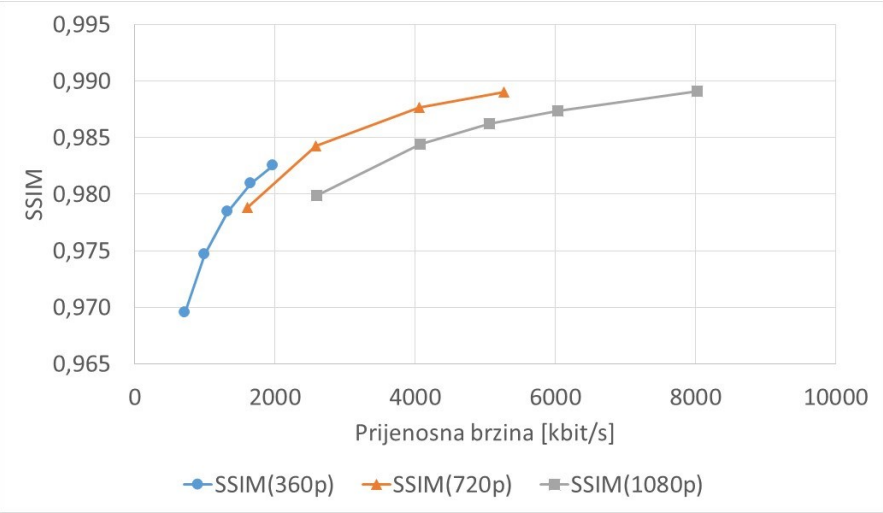
Slika 3.4. Grafički prikaz ovisnosti PSNR-a i prijenosne brzine za *Blue Sky* (BS) videosignal

Budući da PA videosignal ima veći TI od S2 videosignala, te slične vrijednosti SI i PSNR-a, može se zaključiti da TI parametar ima manji utjecaj na kvalitetu kodiranog videosignala, barem za videosignale s niskim TI i SI. Za prijenosne brzine korištene u eksperimentu, vrijednosti PSNR-a kao i SSIM-a za videosignale S2, PA i BS veće su za prostornu rezoluciju 1280 x 720 nego za rezolucije 640 x 360 i 1920 x 1080 što dovodi do zaključka da je u nekim slučajevima preporučljivo koristiti niže prostorne rezolucije kako bi se postigla bolje kvaliteta videosignala. LF videosignal ima vrijednosti SI i TI između onih od S2 i BS, ali za rezoluciju 1980 x 1080 ostvaruje najveće vrijednosti PSNR u usporedbi s drugim prostornim rezolucijama. Rezultati PSNR-a za LF videosignal pri prostornoj rezoluciji 1280 x 720 razlikuju se od ostalih što se može objasniti činjenicom da je LF jedini videosignal koji je animirani film odnosno umjetno generiran videosignal, dok su drugi videosignali snimljeni kamerom.

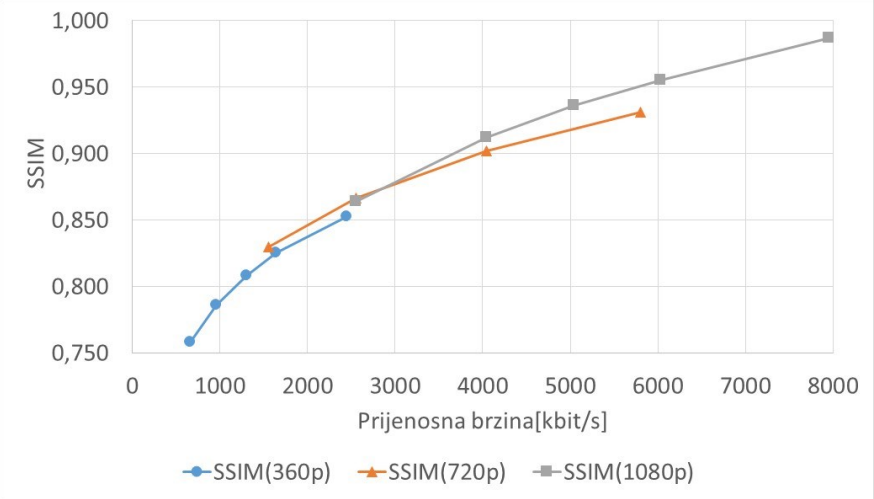
Za potrebe videostrujanja i implementacije MPEG DASH-a, pravilan odabir prostorne i vremenske rezolucije vrlo je važan za odabir reprezentacija segmentiranih videosignala. Rezultati pokazuju da prostorna aktivnost ima velik utjecaj na PSNR i SSIM, tako da postupak odabira treba sadržavati prostorne i vremenske informacije o videosadržaju kako bi se postigla najbolja moguća kvaliteta videosignala. Utjecaj vremenske aktivnosti potrebno je u budućnosti dodatno istražiti na primjeru videosignala s višim vrijednostima SI i međusobno sličnim vrijednostima TI.



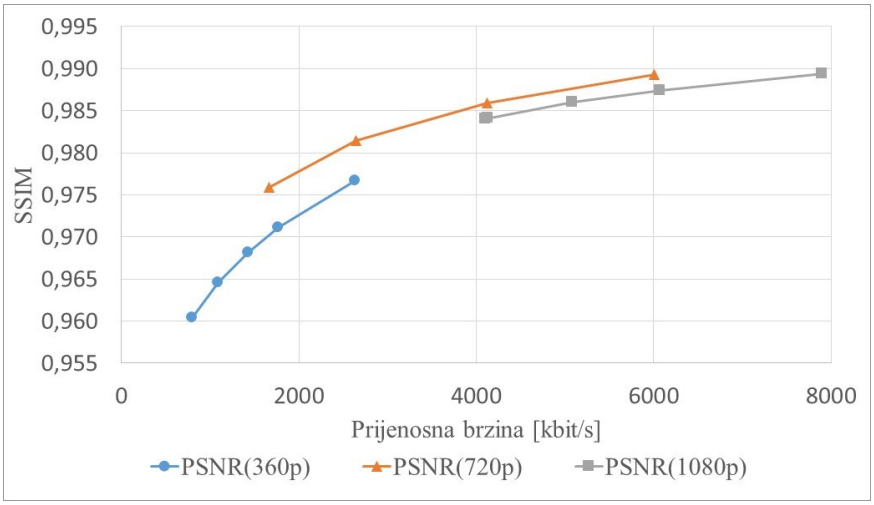
Slika 3.5. Grafički prikaz ovisnosti SSIM-a i prijenosne brzine za *Station2* (S2) videosignal



Slika 3.6. Grafički prikaz ovisnosti SSIM-a i prijenosne brzine za *Pedestrian Area* (PA) videosignal



Slika 3.7. Grafički prikaz ovisnosti SSIM-a i prijenosne brzine za *Life* (LF) videosignal



Slika 3.8. Grafički prikaz ovisnosti SSIM-a i prijenosne brzine za *Blue Sky* (BS) videosignal

Na temelju preliminarnih istraživanja na četiri videosignala, iz dostupnih baza videosignala [4, 72, 73] za potrebe razvoja metode za odabir optimalnih razina kvalitete u postupku kodiranja i segmentacije odabrano je šesnaest videosignala s različitim prostornim i vremenskim informacijama. Prostorne i vremenske informacije za ove videosignale izračunate su pomoću (3-1) i (3-2) kao srednje vrijednosti SI i TI za Y komponentu izvornih videosignala koji su dostupni u YUV formatu.

Osim SI i TI parametara, u daljnjim analizama korišten je parametar SITI koji predstavlja mjeru ukupne prostorno-vremenska aktivnost videosadržaja, a određen na sljedeći način:

$$SITI = SI \cdot TI \tag{3-3}$$

Vrijednosti SI i TI, kao i SITI za videosignale odabrane za daljnja istraživanja, prikazane su u tablici 3.4.

Tablica 3.4. Prostorna i vremenska informacija videosadržaja odabranih za daljnja istraživanja

Videosignal	**Oznaka**	**SI**	**TI**	**SITI**
Chimera1102353	C53	13.63	5.51	75.07
Meridian Conversation	MC	28.39	3.10	87.86
Chimera1102347	C47	43.12	5.06	218.36
Station2	S2	32.72	7.50	245.40
Cosmos Laundromat	CL	36.80	12.78	470.34
Pedestrian Area	PA	32.32	15.47	500.11
Skateboarding	SK	26.72	20.23	540.48
Grand Theft Auto	GTA	47.63	18.09	861.65
Of Forest And Men	OFAM	50.93	19.01	968.18
Tears Of Steel Robot	TSR	44.78	22.22	995.02
El Fuente Dream	ED	41.59	25.93	1078.30
El Fuente Mask	EM	54.92	24.71	1357.14
Soccer	SO	79.06	24.71	1953.52
BlueSky	BS	78.64	33.41	2627.31
Big Buck Bunny	BBB	31.84	7.22	229.88
Elephants Dream	ED	50.93	8.75	445.64
Tractor	TR	34.99	18.83	658.69

Videosignali odabrani su kako bi se pokrilo širok raspon vrijednosti SI i TI , kao i SITI. Videosignali *Big Buck Bunny* (BBB), *Elephants Dream* (ED) i *Tractor* (TR) [73] odvojeni su u tablici jer nisu korišteni u procesu inicijalnih ispitivanja, modeliranja i razvoja metode, ali su kasnije korištene za vrednovanje predloženih modela. Svi videosignali osim BBB i ED korišteni u postupku modeliranja duljine su 20 do 30 sekundi kako bi se ubrzao proces višestrukog probnog kodiranja i subjektivne ocjene kvalitete. Za ispitivanje su korišteni videosignali TR duljine 28 sekundi, BBB duljine 9 minuta i 56 sekundi i ED duljine 10 minuta i 54 sekunde. Slike odabranih videosignala prikazani su na slici 3.9. kako bi se prikazala vrsta sadržaja. Svi videosignali imaju prirodni sadržaj, osim CL videosignala koji je animacija.



Slika 3.9. Slike iz videosignala: a) *Blue Sky* (BS) b) Chimera1102353 (C53) c) *Pedestrian Area* (PA) d) Station2 (S2) e) Chimera1102347 (C47) f) Cosmos Laundromat (CL) g) *El Fuente Dance* (ED) h) *Meridian Conversation* (MC) i) *Skateboarding* (SK) j) *Soccer* (SO)

3.2. Metode za ocjenu kvalitete videosignala

Za procjenu kvalitete kodiranog videosignala i videosignala nakon strujanja u sustavima zasnovanim na MPEG DASH normi mogu se koristit različite dostupne metode koje se mogu podijeliti na objektivne i subjektivne metode. Objektive metode za ocjenu kvalitete videosignala određuju kvalitetu videosignala pomoću računalnih algoritama, dok subjektivne metode za ocjenu kvalitete podrazumijevaju ocjenu videosignala uz pomoć iskusnih ili neiskusnih gledatelja.

Obje skupine metoda daju važan uvid u kvalitetu videosignala te se ostvareni rezultati koriste za unapređenje algoritama za videostrujanje, određivanje parametara kodiranja i segmentacije videosignala.

3.2.1. Subjektivne metode za ocjenu kvalitete videosignala

Subjektivne metode za ocjenu kvalitete videosignala uključuju provođenje subjektivnog eksperimenta uz pomoć određenog broja ljudi kojima se prikazuje niz videosignala koje zatim korisnici ocjenjuju u ovisnosti o tome što su vidjeli i doživjeli. Subjektivna kvaliteta videosignala često se ocjenjuje pomoću MOS (eng. *Mean Opinion Score*) skale koja potječe iz domene subjektivne ocjene kvalitete zvuka [74]. Korisnicima se u pravilu na početku opisuje tijek samog eksperimenta te ljestvica od jedan do pet koja će se koristiti za ocjenu kvalitete videosignala kojoj odgovaraju oznake „izvrsno“, „dobro“, „zadovoljavajuće“, „loše“ i „jako loše“.

Prije subjektivnog ispitivanja potrebno je odrediti broj ispitanika, hoće li se ispitivanje vršiti u kontroliranom ili nekontroliranom okruženju, imaju li ispitanici iskustva u polju istraživanja ili ne i sl. S obzirom da subjektivna ocjena kvalitete ovisi o mnogo parametara kao što su prethodno iskustvo korisnika, okruženje, preferencije u smislu sadržaja, parametri zaslona na kojima se prikazuje videosignal i slično, ITU-T preporuka P.913 [75] definira standardne uvjete gledanja, postupke ocjenjivanja, kriterije za odabir ispitivanih korisnika i materijala te metode analize podataka, upravo kako bi se smanjio utjecaj vanjskih čimbenika kroz precizne upute i kontrolirane uvjete ispitivanja.

Postoje različite subjektivne metode za ocjenu kvalitete videosignala koje se mogu podijeliti na metode jednostrukog podražaja i metode dvostrukog ili višestrukog podražaja.

- Metode jednostrukog podražaja (engl. *Single Stimulus Methods*):

Absolute Category Rating - ACR metoda se koristi za ocjenjivanja svakog videosignala ljestvicom od jedan do pet. Videosignali se prilikom korištenja ove metode prikazuju gledateljima jedan po jedan i nakon svakog pregledanog videosignala, gledatelji ocjenjuju videosignal.

Absolute Category Rating with Hidden Reference - ACR-HR je varijacija ACR metode, a razliku je po tome što se uz svaki videosignal koji se razlikuje sadržajem prikazuje i izvorni videosignal bez se da se korisnika obavijesti o postojanju skrivenog referentnog videosignala. Kao i u prethodnoj metodi, gledatelji ocjenjuju videosignal nakon svakog pregledanog videosignala.

Single Stimulus Continuous Quality Evaluation – SSCQE metoda se koristi za ocjenjivanje duljih videosignala te se ocjena za jedan videosignal daje nekoliko puta u jednako raspoređenim intervalima. Za razliku od prethodne dvije metoda, SSCQE kao rezultat daje krivulju ocjene kvalitete u ovisnosti o vremenu, a ne samo jednu ocjenu kao što je to bio slučaj u prethodne dvije metode. Također, kada se koristi SSCQE metoda, gledateljima se prikazuje samo kodirana verzija videosignala, ali ne i izvorni videosignal.

- Metode dvostrukog podražaja (engl. *Double Stimulus Methods*):

Double Stimulus Continuous Quality Scale - DSCQS metoda kao i ACR-HR koristi referentne videosignali prilikom ocjene kvalitete kodiranih videosignala te koristi istu ljestvicu prilikom ocjenjivanja. Za razliku od ACR-HR, prilikom korištenja DSCQS metode, gledateljima se slučajnim redoslijedom prikazuju kodirani i izvorni videosignali s tim da gledatelji nisu obavješteni o tome koji je videosignal izvorni videosignal. Ova metoda također dopušta gledateljima da ponovno pregledavaju videosignale i zatim daju konačnu ocjenu. Postoje dvije vrste prikazivanja videosignala kod DSCQS metode. Moguće je gledateljima prikazivati po dva videosignala istovremeno (prikazivanje se ponavlja određeni broj sekundi nakon koji gledatelj treba ocijeniti oba videosignala) ili jedan za drugim (gledatelj unutar unaprijed određenog perioda može sam prebacivati između dva videosignala koja trenutno ocjenjuje).

Double Stimulus Impairment Scale - DSIS odnosno *Degradation Category Rating* - DCR je metoda u kojoj se gledateljima prvo prikazuje referentni videosignal za koji gledatelj ne zna da se radi o referentnom videosignalu, a zatim se prikazuje kodirani videosignal za koji se potom traži od gledatelja da ga ocijeni ljestvicom od jedan do pet. Postupak prikazivanja prvo referentnog pa zatim kodiranog videosignala se ponavlja za svaki videosignal koji je potrebno ocijeniti zbog čega ova metoda zahtjeva više vremena za samo ispitivanje s tim da je ispitivanje vremenski ograničeno na 30 minuta.

Comparison Category Rating - CCR odnosno *Pair Comparison* - PC metoda se koristi na način da se gledateljima prikazuju samo kodirani videosignali, ali u paru. Gledateljima se prikazuju sve kombinacije videosignala koje ocjenjuju nakon svakog pregledanog para videosignala.

Subjective Assessment Method for Video Quality - SAMVIQ metoda osigurava najviše autonomije prilikom ocjenjivanja videosignala jer gledatelji imaju mogućnost pregledavanja nasumično poredanih videosignala kao i referentnog videosignala nekoliko puta, mogu se vraćati na pojedine videosignale i mijenjati svoju ocjenu. Također, gledatelji imaju mogućnost sami odrediti brzinu provođenja postupka ocjenjivanja odnosno mogu sami zaustaviti i nastaviti prikazivanje određenog videosignala.

Zajedničko ovim metodama je činjenica da se obavljaju u zatvorenom prostoru bilo da se radi o kontroliranom laboratorijskom okruženju ili ne. U slučaju da se ne koristi kontrolirano okruženje, norma propisuje veći broj gledatelja za pojedino ispitivanje. Izbor metode prvenstveno ovisi o tome što se mjerenjem želi ostvariti kao i o karakteristikama samih videosignala koji se analiziraju. DCR metoda je na primjer dobra za analizu videosignala nakon strujanja kao i ACR-HR metoda koja uklanja dio utjecaja sadržaja na ocjenu kvalitete videosignala te se često koristi za usporedbu dva različita sustava prijenosa ili kodiranja, ali se ne bi trebala koristiti kada je referentni videosignal loše kvalitete.

Iako se subjektivna ocjena kvalitete često smatra točnijom ocjenom u odnosu na objektivu ocjenu kvalitete postoji mnogo istraživanja koja ističu negativne aspekte subjektivnog ispitivanja. Glavni nedostatak subjektivni eksperimenata je potreba za velikim brojem gledatelja, minimalno 8 do 12 za inicijalna ispitivanja i 24 do 35 za završna ispitivanja s tim da je ispitivanja uvijek potrebno napraviti i pomoću većeg broja gledatelja od minimalno pripisanih zbog toga što je moguće da će se nakon provjere rezultata rezultati dijela gledatelja morati ukloniti iz analize.

Također, duljina videosignala i trajanje cjelokupnog ispitivanja je također propisana normom što u pojedinim slučajevima znači da će se gledatelji za ispitivanje morati okupiti nekoliko puta [75]. Kao što je već istaknuto ranije, okruženje može znatno utjecati na ocjenu videosignala te iako provođenje ispitivanja u kontroliranom okruženju ima svoje prednosti, sama činjenica da se gledatelji ne nalaze u svom „prirodnom“ okruženju također ima utjecaj na ocjenu [76]. Istraživanjem intervala MOS ljestvice utvrđeno je da su nejednaki na konceptualnoj razini jer korisnici obično nemaju svijest o točnosti svojih rezultata [76, 77].

3.2.2. Objektivne metode za ocjenu kvalitete videosignala

Razvoj algoritama za videostrujanje zadnjih je godina usmjeren na poboljšanje kvalitete korisničkog iskustva što se ostvaruje korištenjem parametara proizašlih iz ocjena kvalitete videosignala određenih pomoću različitih metoda za subjektivnu i objektivu ocjenu videosignala [78]. Pouzdanost objektivnih VQA metoda obično se provjerava i kvantificira usporedbom

rezultata s odgovarajućim rezultatima subjektivnog ispitivanja, no objektivne VQA metode i dalje su važan dio ispitivanja usluga, jer je subjektivno ispitivanje dugotrajno, skupo i ne može u stvarnom vremenu osigurati ocjenu kvalitete videosignala [79].

Stoga je analiza objektivnih VQA metoda korištenjem različitih videosignala s različitim prostornim i vremenskim aktivnostima i s različitom prostornom i vremenskom rezolucijom važna za daljnju optimizaciju postupaka ispitivanja ABR algoritama. Ideja istraživanja koje slijedi je analizirati učinkovitost VQA metoda na strani poslužitelja, kako bi se poboljšao odabir optimalnih kodnih brzina i prostornih rezolucija s obzirom na mrežne uvjete, ali i prostorne i vremenske aktivnosti videosadržaja.

Objektivne VQA metode mogu se podijeliti na:

- metode koje zahtijevaju dostupnost cjelokupnog referentnog videosignala (engl. *Full Reference* - FR) [79]
- metode koje zahtijevaju dostupnost dijela značajki referentnog videosignala (engl. *Reduced Reference* - RR) [80, 81],
- metode koje predviđaju kvalitetu bez upotrebe bilo kakvih referentnih podataka i ne trebaju nikakve informacije o izvornom videosignalu (engl. *No-reference* - NR) [82, 83].

S obzirom da su objektive metode za ocjenu kvalitete već dugi niz godina tema istraživanja, postoji mnogo dostupnih metoda koje se mogu koristiti za ocjenu kvalitete videosignala. Za potrebe ovog istraživanja odabrano je nekoliko FR objektivnih VQA metoda: srednja vrijednost sume razlika boje u promatranim elementima slike (DELTA) [84], srednja vrijednost sume apsolutnih razlika (engl. *Mean Sum of Absolute Differences* - MSAD), srednja kvadratna pogreška (engl. Mean Squared Error - MSE), PSNR, SSIM, indeks strukturne sličnosti na više razina (engl. *MultiScale Structural Similarity Indeks Measure* - MS-SSIM) [85, 86], vizualni odnos signala i šuma (engl. *Visual Signal to Noise Ratio* - VSNR) [87], VMAF (engl. *Video Multimethod Assessment Fusion*) [62], i RR metoda za ocjenu kvalitete videosignala zasnovana na diskretnoj kosinusnoj transformaciji (engl. *Discrete Cosine Transform-based Video Quality Metric* - VQM) [88].

MSE, PSNR, DELTA i MSAD su VQA metode koji ne uzimaju u obzir karakteristike ljudskog vizualnog sustava (engl. *Human Visual System* - HVS). MSE i PSNR temelje se na statističkoj obradi srednje vrijednosti kvadrata razlike elemenata slike, stoga ne postižu visoku korelaciju sa subjektivnim VQA rezultatima.

MSE se za videosignal s T slika definira pomoću izraza (3-4) gdje umnožak M i N određuje broj elemenata slike. x predstavlja sliku referentnog videosignala, a y sliku kodiranog videosignala.

$$MSE(x,y) = \frac{1}{M \cdot N \cdot T} \sum_{t=1}^{T} \sum_{n=1}^{N} \sum_{m=1}^{M} [x(n,m,t) - y(n,m,t)]^2 \quad . \tag{3-4}$$

Za razliku od MSE, PSNR koristi logaritamsku ljestvicu i definira se pomoću izraza (3-5) gdje je R broj bita po elementu slike za pojedinu komponentu videosignala , a $2^R - 1$ najveća vrijednost amplitude određenog elementa slike.

$$PSNR = 10\, log_{10} \frac{(2^R-1)^2}{MSE} \ , \tag{3-5}$$

DELTA za procjenu kvalitete koristi prosječnu razliku vrijednosti elemenata slike u referentnom i kodiranom videosignalu. Definira se pomoću izraza (3-6) gdje umnožak M i N određuje broj elemenata slike. x predstavlja sliku referentnog videosignala, a y sliku kodiranog videosignala.

$$DELTA(x,y) = \frac{1}{M \cdot N \cdot T} \sum_{t=1}^{T} \sum_{n=1}^{N} \sum_{m=1}^{M} x(n,m,t) - y(n,m,t) \quad . \tag{3-6}$$

MSAD koristi srednju apsolutnu razliku vrijednosti elemenata slike u referentnom i kodiranom videosignalu za procjenu kvalitete [84]. Definira se pomoću izraza (3-7) gdje umnožak M i N određuje broj elemenata slike. x predstavlja sliku referentnog videosignala, a y sliku kodiranog videosignala.

$$MSAD(x,y) = \frac{1}{M \cdot N \cdot T} \sum_{t=1}^{T} \sum_{n=1}^{N} \sum_{m=1}^{M} |x(n,m,t) - y(n,m,t)| \quad . \tag{3-7}$$

Prema dostupnim istraživanjima bolja korelaciju sa subjektivnim VQA rezultatima ostvaruje se pomoću SSIM i MS-SSIM modela jer uzimaju u obzir karakteristike HVS-a. MS-SSIM koristi proračun strukturnih izobličenja, ali na više razina (skala). SSIM i MS-SSIM uspoređuju strukturne značajke videosignala za razliku od prethodnih metoda koje su uspoređivale vrijednosti elemenata slike [62, 80, 87].

SSIM metoda za proračun mjere strukturnog izobličenja koristi srednje vrijednosti, μ_x *i* μ_y i varijance, σ_x *i* σ_y referentnog videosignala x i kodiranog videosignala y. Definira se pomoću izraza (3-8) gdje su C_1 i C_2 konstante pomoću kojih se ostvaruje bolje stabilnost proračuna [80].

$$SSIM(x,y) = \frac{(2 \cdot \mu_x \cdot \mu_y + C1)(2 \cdot \sigma_x \cdot \sigma_y + C2)}{(\mu_x{}^2 + \mu_y{}^2 + C1) + (\sigma_x{}^2 + \sigma_y{}^2 + C2)} \tag{3-8}$$

MS-SSIM metoda koja kvalitetu videosignala određuje uzimajući u obzir karakteristike HVS-a, sposobnost opažanja detalja slike, udaljenost gledatelja i ravnine slike te gustoću uzorkovanja signala slike opisana je pomoću izraza (3-9). Koristi kao i SSIM srednje vrijednosti, μ_x *i* μ_y i varijance, σ_x *i* σ_y referentnog videosignala *x* i kodiranog videosignala *y*. Parametri α_M, β_j i γ_j su parametri koji određuju relativni utjecaj komponenata na koje se odnose, a C_1, C_2 i C_3 su konstante pomoću kojih se ostvaruje bolje stabilnost proračuna. Proračun se vrši za *M* mogućih razina [86].

$$MS-SSIM(x,y) = \left(\frac{2\cdot\mu_x\cdot\mu_y+C1}{\mu_x{}^2+\mu_y{}^2+C1}\right)^{\alpha_M} \cdot \prod_{j=1}^{M}\left[\left(\frac{2\cdot\sigma_x(j)\cdot\sigma_y(j)+C2}{\sigma_x(j)^2+\sigma_y(j)^2+C2}\right)^{\beta_j} \cdot \left(\frac{\sigma_{xy}(j)+C3}{\sigma_x\cdot\sigma_y(j)+C3}\right)^{\gamma_j}\right] \qquad (3\text{-}9)$$

VSNR metoda zasnovana je na diskretnoj valić transformaciji (eng. *Discrete Wavelet Transform* - DWT) i koristi svojstva niske razine osjetljivosti HVS-a i vizualnog maskiranja te svojstva srednje razine globalne prednosti u procesu donošenja odluka. Uzima se u obzir svojstva HVS-a blizu i iznad određenog praga vidljivosti kako bi se utvrdila vizualna točnost analiziranog videosignala. Oba svojstva prikazana su kao euklidske udaljenosti. VSNR se određuje kao linearni zbroj tih udaljenosti. VSNR odlikuju velika učinkovitost s obzirom na memorijske zahtjeve i računalnu složenost [87].

VMAF metoda također dobro korelira s MOS-om zbog činjenice da kombinira više elementarnih značajki kvalitete videosignala. Model za procjene kvalitete videosignala razvijen je pomoću velikog skupa podataka MOS-a te je najosjetljiviji na pogoršanje kvalitete koje se javlja zbog skaliranja i kompresije. Kvaliteta videosignala izračunava se iz rezultata različitih VQA modela i njihovim kombiniranjem pomoću vektorskog stroja za podršku (engl. *support vector machine*) [62].

VQM metrika koristi diskretnu kosinusnu transformaciju (engl. *Discrete Cosine Transform* - DCT) za izračunavanje izobličenja u videosignalima. Vrijednost VQM-a povećava se sa smanjenjem kvalitete u analiziranom videosignalu. Definira se pomoću izraza (3-10) gdje *x* predstavlja sliku referentnog videosignala, a *y* sliku kodiranog videosignala, *DC* je rezultat DCT za frekvencije (0,0), *CFS* je funkcija kontrastne osjetljivosti HVS-a [88].

$$VQM(x,y) = mean(\left|\frac{DCT_{xy}\cdot DC}{2^{20}}\cdot CSF_{xy}\right| + 0.005\cdot max(\left|\frac{DCT_{xy}\cdot DC}{2^{20}}\cdot CSF_{xy}\right|) \qquad (3\text{-}7)$$

3.2.2.1. Dostupna istraživanja

QoS koji se koristi za analizu različitih multimedijskih usluga ovisi o vrsti usluge za koju se parametri analiziraju. U današnje vrijeme dobro je poznato da očekivanja korisnika vezana uz isporučenu kvalitetu videosignala često ne odgovaraju zaključcima dobivenim iz izmjerenih mrežnih parametara. Korisno je prikupiti informacije o mrežnim parametrima kako bi se steklo znanje o određenim događajima u mreži, ali te informacije ne mogu dovoljno dobro opisati korisničko iskustvo [89].

Kao što je prethodno spomenuto, postoje različiti tehnički čimbenici kao što su snimanje ili generiranje videosignala, kodiranje, kompresije, prijenos videosignala, dekodiranje i reprodukcija, koji mogu smanjiti kvalitetu videosignala. Uzimajući u obzir da različiti tehnički čimbenici i čimbenici koji nisu tehničke prirode utječu na korisničko iskustvo, optimizacija i mjerenje kvalitete signala složen je zadatak [90]. Korisnici općenito vide videosignale s visokim kontrastom kao videosignale s boljom kvalitetom, dok videosignale s malom svjetlinom, kontrastom i oštrinom vide kao signale s niskom kvalitetom [91]. ITU-T navodi da je subjektivno ispitivanje provedeno s grupom od najmanje 15 pojedinaca najpreciznija VQA metoda [92].

Kada se govori o ocjeni kvalitete videosignala nakon prilagodljivnog strujanja važno je navesti da je QoE niži ako postoji značajno početno kašnjenje ili postoji pogoršanje u prvom vremenskom segmentu videosignala [93]. Također QoE je viši u slučajevima prebacivanja između uzastopnih razina kvalitete videosignala u usporedbi s trenutnim prebacivanjem između razina kvalitete za više od jednog koraka. Ovi se utjecaji najbolje mogu ocijeniti subjektivnim VQA metodama, međutim, zbog manjkavosti subjektivnog ispitivanja poput činjenice da prethodna iskustva gledatelja i njihove preferencije mogu ugroziti rezultate ispitivanja, te dugotrajnosti i cijene samog ispitivanja [53, 89], potrebno je ispitati koja objektivna metoda najbolje korelira sa subjektivnim ocjenama.

U dostupnoj literaturi mogu se naći rezultati ispitivanja prikladnosti različitih objektivnih metoda za ocjenu kvalitete videosignala nakon adaptivnog strujanja kao i objektivne VQA metode posebno razvijene za tu namjenu. U [87] predstavljeno je istraživanje koje pokazuje da rezultati dobiveni objektivnim VQA metodama poput MSE i PSNR imaju nisku korelaciju sa subjektivnim ocjenama kvalitete, jer ne uzimaju u obzir svojstva HVS-a, no postoje i istraživanja koja navode da PSNR i SSIM imaju dobru korelaciju sa subjektivnim ispitivanjem [87, 94, 95].

Iz istraživanja [96] koje uspoređuje PSNR, SSIM, MS-SSIM i VMAF metode može se zaključiti da PSNR ostvaruje najlošije rezultate od analizirane četiri metode zbog činjenice da ne

uzima u obzir svojstva HVS-a. SSIM ostvaruje nešto bolje rezultate u usporedbi s PSNR-om, posebno u slučajevima kada su postojale slike s izobličenjima iznad praga vidljivosti. S obzirom na to da MS-SSIM radi proračun na više razina, pokazao se boljim od SSIM-a. VMAF je postigao najbolje rezultate u slučaju kada se koristio Netflix-ov skup podataka [96]. U istraživanjima opisanim u [97, 98] navedeno je da MS-SSIM i VQM ostvaruju približno jednake rezultate.

Kako bi se identificirala najbolja objektivna VQA metoda koja će se koristiti u istraživanjima optimizacije postupka segmentacije videosignala na strani poslužitelja, kao i za ispitivanje ABR algoritama koji koriste skaliranje prostornih rezolucija, provedeno je usporedba rezultata devet objektivnih VQA metoda s rezultatima subjektivnog ispitivanja. Pri tome je korišteno deset videosignala s različitim SI i TI parametrima, kodiranim na tri prostorne rezolucije i različitim kodnim brzinama, što imitira scenarij korišten u uslugama za strujanje videosignala.

3.2.2.2. Usporedba objektivnih metoda za ocjenu kvalitete videosignala

Deset različitih videosignala (često korištenih u ispitivanju ABR algoritama) odabrano je za potrebe ispitivanja na temelju njihove prostorne i vremenske aktivnosti. Svi videosignali kodirani su na tri prostorne rezolucije i s različitim kodnim brzinama, od 600 kbit/s do 12600 kbit/s. VQA metode analizirane u ovom ispitivanju su MSE, PSNR, VSNR, SSIM, MS-SSIM, DELTA, MSAD, VQM i VMAF. Rezultati su prikupljeni pomoću MSU alata za mjerenje kvalitete [20]. Svi odabrani videosignali dostupni su u prostornoj rezoluciji 1920 x 1080 (FullHD) s 25 slika po sekundi. Referentni videosignali korišteni u ovom istraživanju su: *Blue Sky* (BS), *Chimera1102353* (C53), *Station2* (S2), *Pedestrian Area* (PA), *Chimera1102347* (C47), *Cosmos Laundromat* (CL), *El Fuente Dance* (ED), *Meridian Conversation* (MC), *Skateboarding* (SK) i *Soccer* (SO). BS, S2, PA preuzeti su iz baze videosignala objavljene u [73]. Ostali videosignali preuzeti su iz baze videosignala objavljene u [72].

Iz tablice 3.4. vidi se da PA i S2 imaju sličan SI, ali različit TI. Videosignali C53 i C47 imaju sličan TI, ali različit SI. Isto se odnosi na ED i SO. SO je videosignal s najvećim SI, BS je videosignal s najvišim TI, dok je C53 videosignal s najnižim SI, a MC videosignal s najnižim TI. Ovi podaci SI i TI važni su za analizu VQA metoda.

Svi odabrani videosignali prvo su kodirani na tri prostorne rezolucije: nHD (640x360), HD (1280x720) i FullHD (1920x1080), prema H.264/AVC standardu kompresije videosignala s parametrima kodiranja popisanim u tablici 3.5, pomoću FFmpeg-a [71]. Smanjenje prostorne rezolucije izvršeno na način da je faktor konstantne brzine (engl. Constant Rate Factor – CRF) bio postavljen na nulu odnosno koristilo se kodiranje bez gubitaka čime se osigurava najbolja moguća

kvaliteta izlaznog videosignala. Tijekom postupka kodiranja, parametar *preset* je bio postavljen na *slow* jer predstavlja kompromis između vremena potrebnog za kompresiju i njegove učinkovitosti.

Videosignali su kodirani iz temeljnih videosignala određene prostorne rezolucije uz postavljanje ciljane kodne brzine. Pri tome je korištena CRF vrijednosti 23, što je zadana vrijednost u FFmpeg i najčešće se koristi prilikom kodiranja. Budući da je korišten CRF, postignuta kodna prijenosna brzina može varirati, tj. biti veća ili manja od postavljene kodne brzine, jer se CRF usredotočuje na isporuku tražene razine kvalitete korištenjem prijenosne brzine koja ima vrijednost približnu postavljenoj kodnoj brzini. Očekivano je da će videosignali s visokim SI i TI imati najveću postignutu prijenosnu brzinu za jednaku postavljenu kodnu brzinu.

Sve odabrane kodne brzine prikazane su u Tablici 3.6. U tablici je navedeno ukupno 19 različitih kombinacija prostorne rezolucije i kodnih brzina. Svih deset videosignala s različitim SI i TI kodirano je u navedenih 19 različitih kombinacija što je rezultiralo sa 190 kodiranih videosignala.

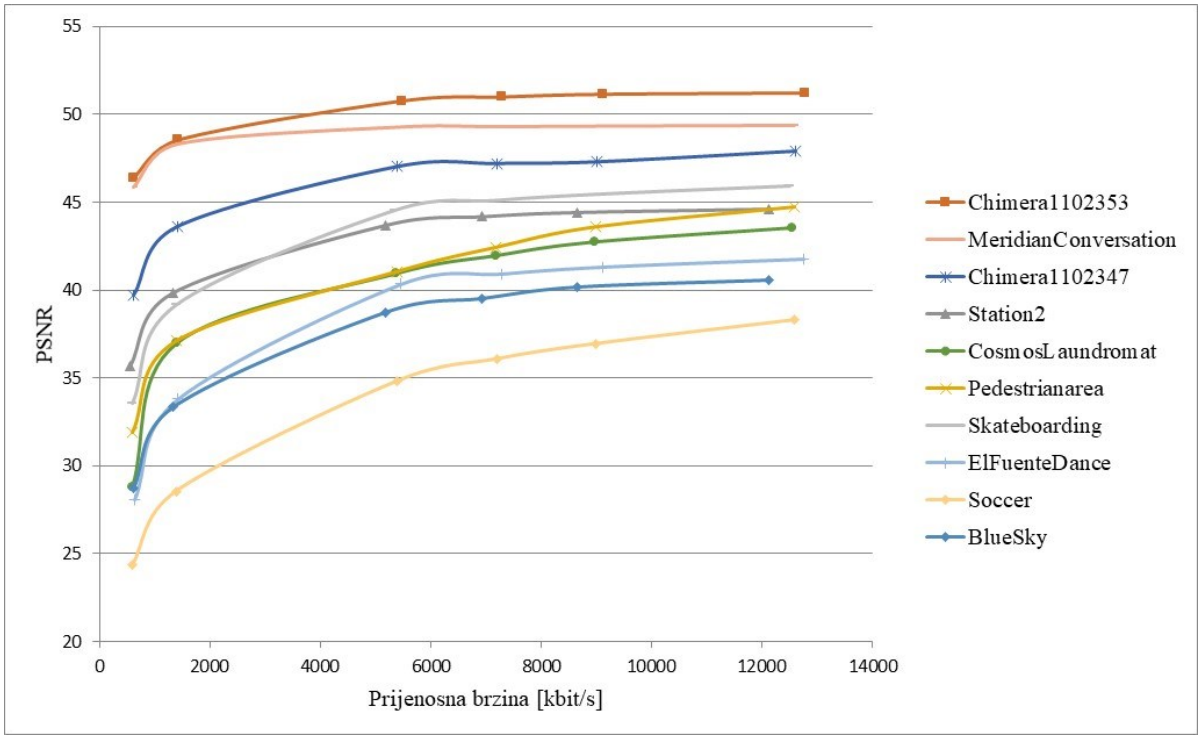
Tablica 3.5. Prostorne rezolucije i kodne brzine korištene u ispitivanju.

Prostorna rezolucija	**Kodna brzina [kbit/s]**
640 x 360	600; 800; 1000; 1400; 2400; 5400
1280 x 720	600; 1400; 2400; 3200; 4000; 5600; 9000
1920 x 1080	600; 1400; 5400; 7200; 9000; 12600

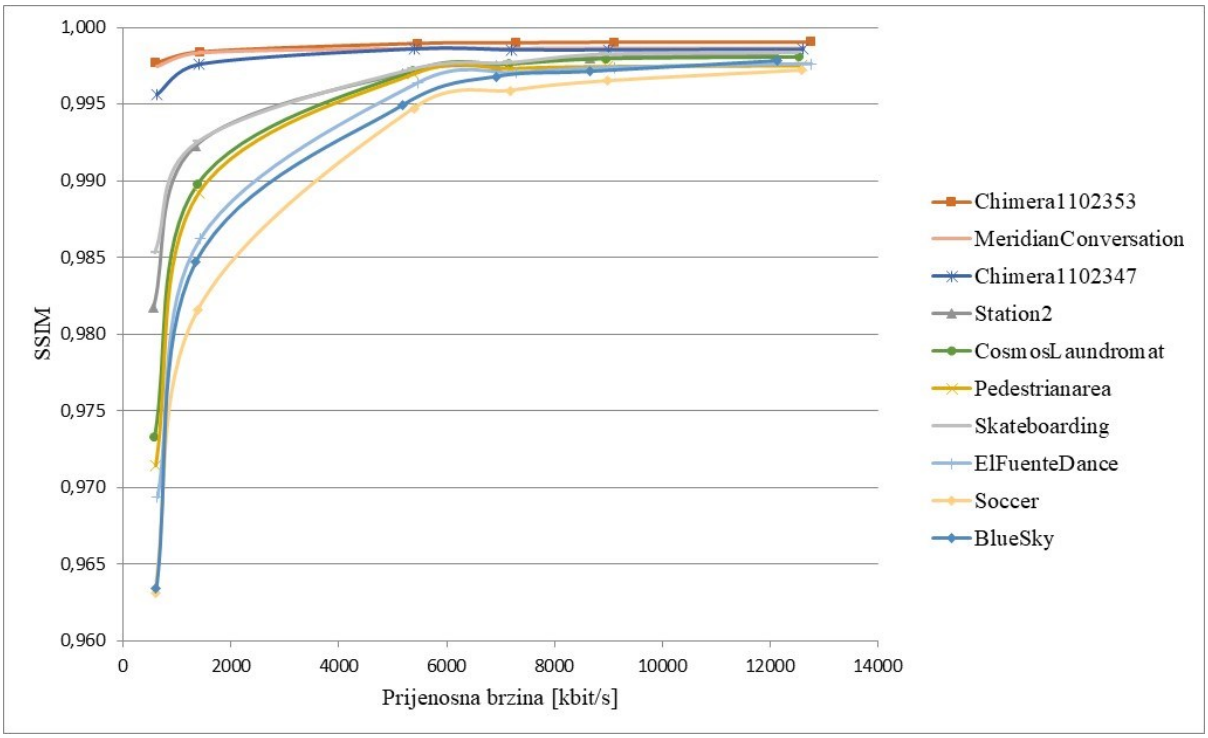
Kako bi se usporedila kvaliteta videosignala s različitim prostornim rezolucijama, prije objektivne i subjektivne ocjene kvalitete, videosignali kodirani na prostorne rezolucije niže od 1920 x 1080, skalirani na 1920 x 1080 prostornu rezoluciju. Bilinearna interpolacija odabrana je kao metoda skaliranja zbog toga što ju odlikuju mala složenost, ali sveukupno zadovoljavajući rezultati. Skaliranje pomoću bilinearne interpolacija također je izvršeno pomoću FFmpeg-a, na taj su način simulirani uvjeti u kojima ABR može zatražiti od poslužitelja videosegmente niže rezolucije zbog promjena u mrežnoj propusnosti, ali videosignal se uvijek prikazuje gledatelju s istom (najvećom mogućom) prostornom rezolucijom.

Slike od 3.10. do 3.13. prikazuju rezultate ispitivanja za VQA metode PSNR, SSIM, VQM i VMAF. Sve slike prikazuju rezultate mjerenja za deset videosignala kodiranih u FullHD

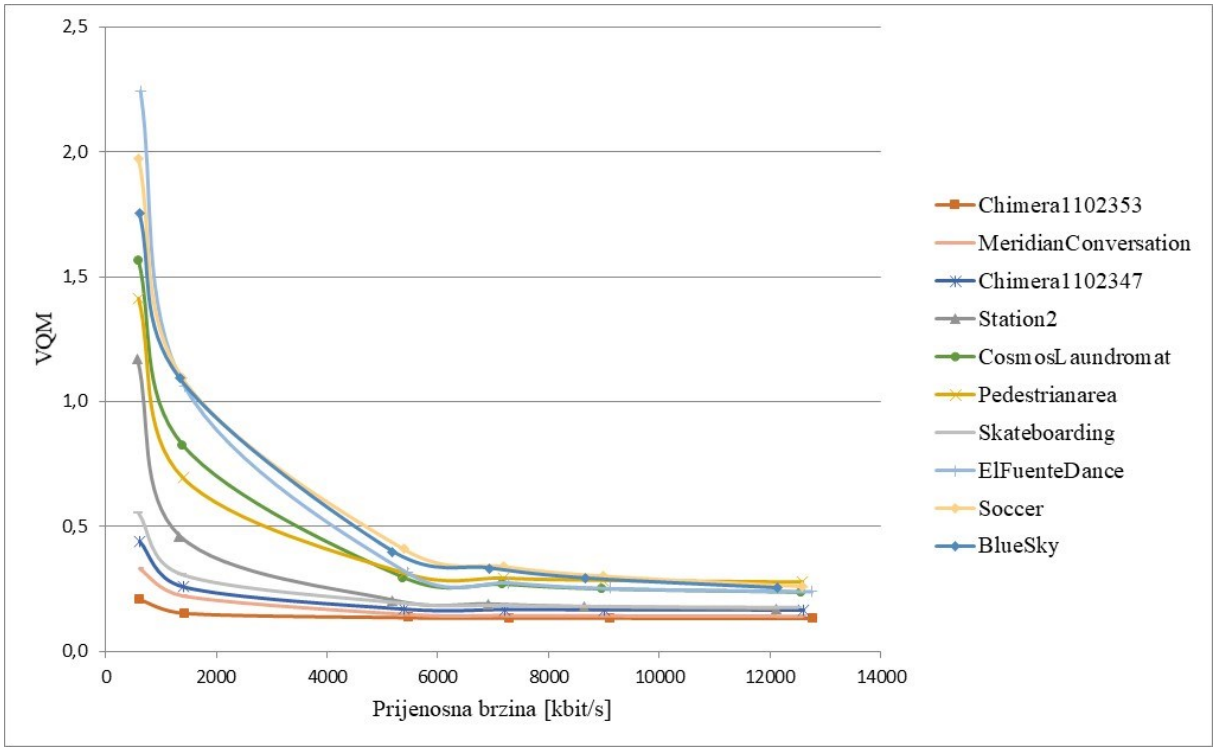
prostornoj rezoluciji s postavljenim kodnim brzinama 600, 1400, 5400, 7200, 9000, 12600 kbit/s. Iz slike 3.10 može se vidjeti da videosignali s višim SI i TI imaju niže vrijednosti PSNR-a iz čega se može zaključiti da su složeniji za kodiranje odabranim parametrima kodiranja. Nadalje, može se zaključiti da videosignali s višom vrijednosti SI imaju niže vrijednosti PSNR-a u slučajevima kada se uspoređuju dva videosignali sa sličnom vrijednosti TI poput C53 i C47. Gledajući vrijednosti za S2 i PA videosignale, može se zaključiti da u slučaju videosignala sa sličnom vrijednosti SI, videosignal s višom vrijednosti TI ima niže vrijednosti PSNR-a. Svi videosignali imaju pad PSNR vrijednosti pri postavljenoj kodnoj brzini od 600 kbit/s zbog izuzetno niske kodne brzine za analiziranu prostornu rezoluciju. Što su vrijednosti SI i TI niže, pad vrijednosti PSNR-a je manji. Slični zaključci vrijede i za ostale VQA metrike, kao što se može vidjeti iz rezultata prikazanih na slikama od 3.11 do 3.13.



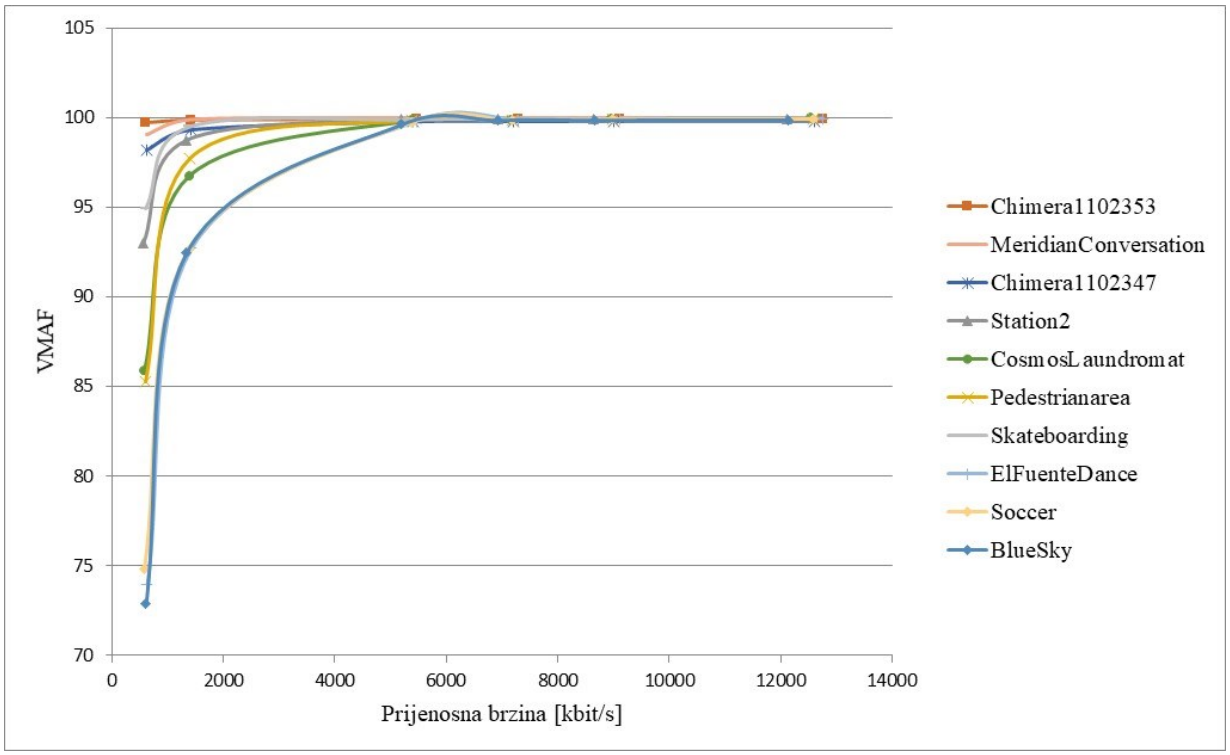
Slika 3.10. PSNR vrijednosti za 1920 x 1080 prostornu rezoluciju



Slika 3.11. SSIM vrijednosti za 1920 x 1080 prostornu rezoluciju



Slika 3.12. VQM vrijednosti za 1920 x 1080 prostornu rezoluciju



Slika 3.13. VMAF vrijednosti za 1920 x 1080 prostornu rezoluciju

Uz objektivno ispitivanje kvalitete, provedeno je i subjektivno ispitivanje za svih 190 videosignala. Subjektivno VQA ispitivanje provedeno je ACR metodom u kontroliranom okruženju s 26 neiskusnih gledatelja [75].

Pokus je proveden u četiri faze:

- informirani pristanak: sudionici su dobili osnovne informacije o ispitivanju, ciljevima ispitivanja, dnevnom redu, zadacima koje trebaju izvesti i trajanju ispitivanja,
- ispitivanje vida sudionika: provedeni su ispiti oštrine vida i Ishihara ispit za raspoznavanje boja,
- upute: sudionici su dobili detaljne upute o procjeni videosignala,
- ocjenjivanje videosignala: ispitivanje je provedeno sa sjednicama fiksnog trajanja s 10 sekundi za glasanje nakon svakog pregledanog videosignala.

Nakon provedenog ispitivanja, MOS je izračunat kao srednja vrijednost prikupljenih rezultata za svaki videosignal. Korištena je ljestvica ocjena od jedan do pet.

Pearson-ov linearni koeficijent korelacije (engl. *Pearson Linear Corellation Coefficient* - PLCC) izračunat je kako bi se utvrdila korelacija između rezultata mjerenja svih objektivnih VQA

metoda i subjektivnih rezultata ispitivanja [99]. Rezultati PLCC izračunati su za svaku prostornu rezoluciju, za svaki videosignal zasebno, zatim za sve videosignale za određenu prostornu rezoluciju i za sve videosignale za određenu objektivnu VQA metodu.

Rezultati za PLCC za sve videosignale pri određenoj prostornoj rezoluciju i ukupno za sve videosignale za svaku objektivnu VQA metodu prikazani su u tablici 3.6. PLCC rezultati za 640 x 360 i 1280 x 720 prostorne rezolucije izračunati su za videosignale skalirane na 1920 x 1080 prostornu rezoluciju. Ukupno je analizirano 190 videosignala za svaku objektivnu VQA metodu. Rezultati su pokazali da je korelacija između rezultata mjerenja subjektivnog i objektivnog VQA-a za većinu VQA metoda najniža za videosignale kodirane u 1280 x 720 rezoluciji. To se može objasniti činjenicom da je broj kodnih brzina koje su korištene u procesu kodiranja za ovu rezoluciju bio najveći.

Općenito, niti jedna od korištenih metoda nije postigla vrlo visoku PLCC vrijednost za sve videosignale. Međutim, SSIM i VQM imaju najviši PLCC (0,7794, odnosno 0,7734), a ukupno postižu najbolje rezultate kada se koriste različite prostorne rezolucije. Iako SSIM ima najveći PLCC za sve videosignale, VQM postiže najbolje rezultate za 1280 x 720 rezoluciju, tj. kada se koristi veći broj postavljenih kodnih brzina.

S obzirom da SSIM i VQM uzimaju u obzir karakteristike HVS-a, nadmašuju PSNR, DELTA, MSAD, MSE i VSNR metode, što se može vidjeti iz tablice 3.6. Neočekivano niski PLCC rezultati, usporedivi s onima ostvarenim za PSNR koji ima ipak nešto manju vrijednost, ostvareni su za VMAF. Iako VMAF kombinira više elementarnih značajki kvalitete videosignala i osposobljen je za analizu videosignala prilikom strujanja, nije ostvario očekivane rezultate za parametre kodiranja i videosignale korištene u ovom ispitivanju. Djelomično se to može objasniti različitim postavkama za subjektivna ispitivanja koje su se koristile za razvoj VMAF-a, tj. model za VMAF temelji se na pretpostavci da su videosignali prikazani na televizijskom zaslonu s rezolucijom 1920 x 1080 i da su gledatelji na udaljenosti tri puta većoj od visine zaslona (3H). U provedenom ispitivanju, gledatelji su gledali videosignale na računalnom zaslonu na udaljenosti manjoj od 3H.

Analizirajući rezultate za pojedini videosignal može se zaključiti da rezultati objektivnih VQA metoda ostvareni za videosignale s višim vrijednostima TI i SI parametara imaju niži PLCC za sve VQA metode (tablica 3.7. prikazuje SSIM rezultate za C53, CL i SO, ali slični rezultati ostvareni su za sve VQA metode).

Tablica 3.6. PLCC rezultati za videosignale kodirane na 640 x 360, 1280 x 720 i 1920 x 1080 prostornim rezolucijama

Objektivna metoda	Prostorna rezolucija	PLCC	Objektivna metoda	Prostorna rezolucija	PLCC
PSNR	360p	0.685044	MSAD	360p	0.608980
	720p	0.644172		720p	0.605221
	1080p	0.715153		1080p	0.684087
	Svi videosignali	0.708182		Svi videosignali	0.699860
SSIM	360p	0.888921	MSE	360p	0.726784
	720p	0.715210		720p	0.691223
	1080p	0.831389		1080p	0.697680
	Svi videosignali	0.779926		Svi videosignali	0.666198
MS-SSIM	360p	0.718876	VMAF	360p	0.670822
	720p	0.681271		720p	0.585973
	1080p	0.769829		1080p	0.718319
	Svi videosignali	0.711381		Svi videosignali	0.718851
VQM	360p	0.867630	VSNR	360p	0.543860
	720p	0.755780		720p	0.525684
	1080p	0.831150		1080p	0.712838
	Svi videosignali	0.773982		Svi videosignali	0.708905
DELTA	360p	0.823293			
	720p	0.634594			
	1080p	0.830959			
	Svi videosignali	0.649855			

Tablica 3.7. SITI i PLCC vrijednosti za SSIM za videosignale *Chimera1102353* (C53), *Cosmos Laundromat* (CL) i *Soccer* (SO)

Objektivna metoda	Videosignal	SITI	PLCC
SSIM	*Chimera1102353* (C53)	75.07	0.921
	Cosmos Laundromat (CL)	470.34	0.842
	Soccer (SO)	1953.52	0.821

Niže vrijednosti PLCC-a za videosignale s visokim vrijednostima SITI parametra rezultat su prostornog i vremenskog maskiranja pogrešaka koje se javlja zbog velikog broja detalja i brzih pokreta u videosignalima s visokim vrijednostima SI i TI. Objektivne metode uspoređuju videosignale sliku po sliku (FR metode) i ne uzimaju u obzir u dovoljnjoj mjeri učinke prostornog i vremenskog maskiranja, pa za ove brze i složene videosignale obično kvalitetu ocjenjuju rigoroznije u odnosu na gledatelje. To može kao rezultat imati pojavu da objektive metode za ocjenu kvalitete videosignala precijene utjecaj izobličenja videosignala i daju niže objektivne VQA ocjene u odnosu na subjektivne ocjene.

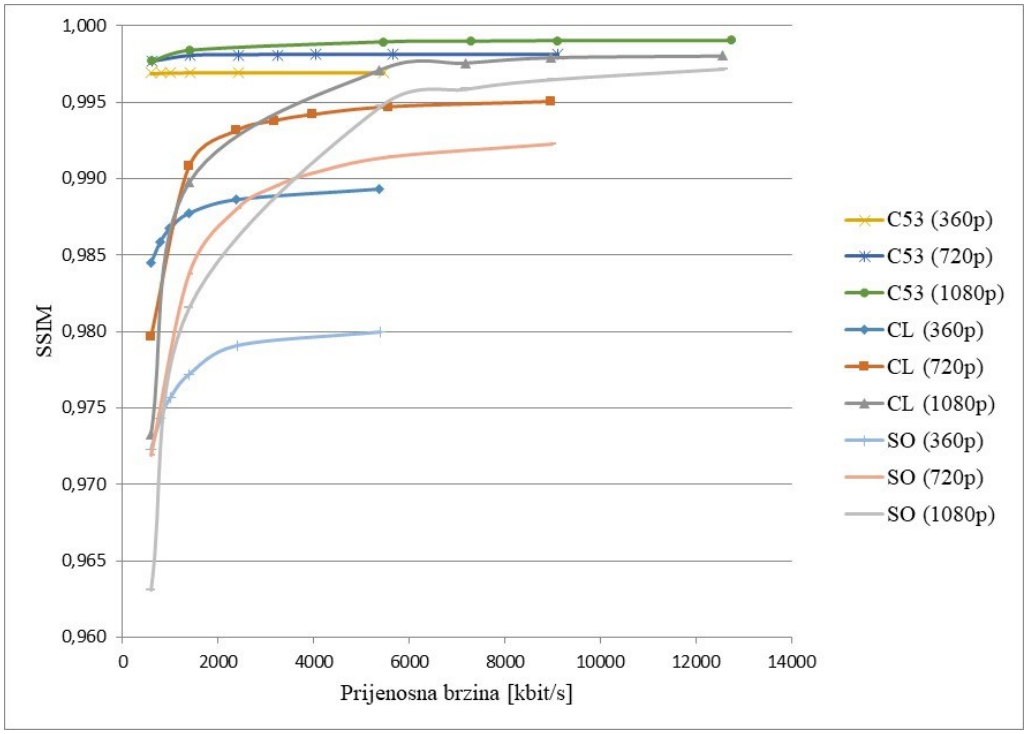
Uzimajući u obzir da ABR algoritmi koriste videosegmente s različitom prostornom rezolucijom, provedena je analiza rezultata danih za svaku prostornu rezoluciju zasebno. Slika 3.14. predstavlja SSIM rezultate za videosignale CL, C53 i SO za sve tri prostorne rezolucije. CL, C53 i SO odabrani su jer C53 ima najniži SITI, SO ima vrlo visoki SITI i najveći SI, a videosignala CL ima srednju vrijednost parametra SITI u odnosu na C53 i SO. Iako su rezultati dani za SSIM, sve ostale objektivne VQA metode daju slične rezultate. Iz slike 3.14. može se zaključiti da su općenito SSIM vrijednosti veće kada je postignuta prijenosna brzina veća i da videosignali kodirani na višoj prostornoj rezoluciji imaju veće SSIM vrijednosti.

Ipak, u slučajevima kada su prostorna i vremenska aktivnost videosignala previsoke da bi se kodirale na niskoj kodnoj brzini i s 1920 x 1080 i 1280 x 720 prostornim rezolucijama, SSIM vrijednosti mogu biti veće u slučaju 640 x 360 prostorne rezolucije. Na primjer, u slučaju SO videosignala koji ima visoku prostornu i vremensku aktivnost, SSIM vrijednosti za kodnu brzinu 600 kbit/s niže su i za 1280 x 720 i za 1920 x 1080 rezoluciju u odnosu na 640 x 360 rezoluciju. U slučaju CL-a koji ima niži SI i TI pri 600 kbit/s, SSIM vrijednost za 1280 x 720 prostornu rezoluciju veća je od one za 1920 x 1080 prostornu rezoluciju. Uzimajući u obzir SI i TI, može se vidjeti da je prijenosna brzina pri kojoj dolazi do preklapanja rezultata za različite prostorne rezolucije veća za videosignale s višim SI i TI.

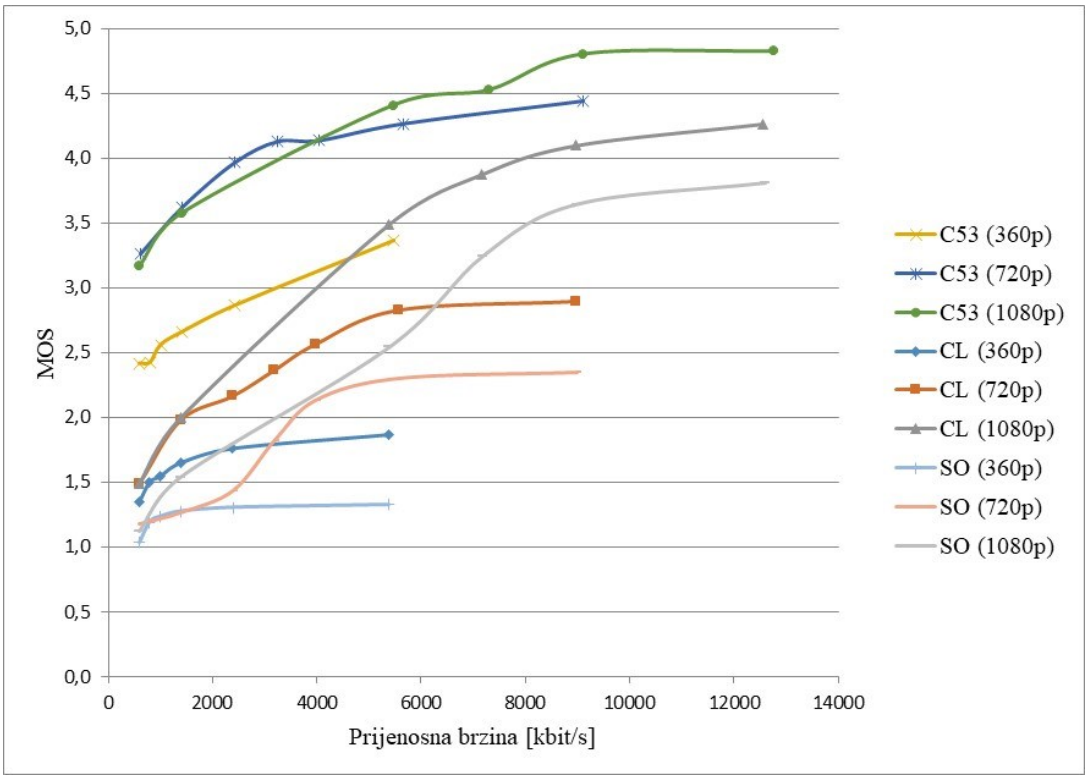
Ovaj zaključak može pomoći u odabiru optimalnih kodnih brzina kod kojih treba promijeniti prostornu rezoluciju, odnosno odabira optimalnih kodnih brzina za svaku prostornu rezoluciju, poboljšavajući tako postupak kodiranja i segmentacije prilikom pripreme videosignala za prilagodljivo strujanje. Jedino se za videosignal C53, koja ima najniži SITI, ne javlja preklapanje za 640 x 360 rezoluciju. Za ovaj videosignal rezultati SSIM-a za 640 x 360 rezoluciju niži su nego za 1280 x 720 i za 1920 x 1080 čak i za 600 kbit/s, jer zbog niske prostorne i vremenske aktivnosti ovog videosignala, koder može

uspješno kodirati na višim prostornim rezolucijama i pri tako niskim brzinama. Može se međutim očekivati da će se preklapanje rezultata za različite rezolucije kod videosignala s tako niskim SITI-jem pojaviti kod još nižih kodnih brzina.

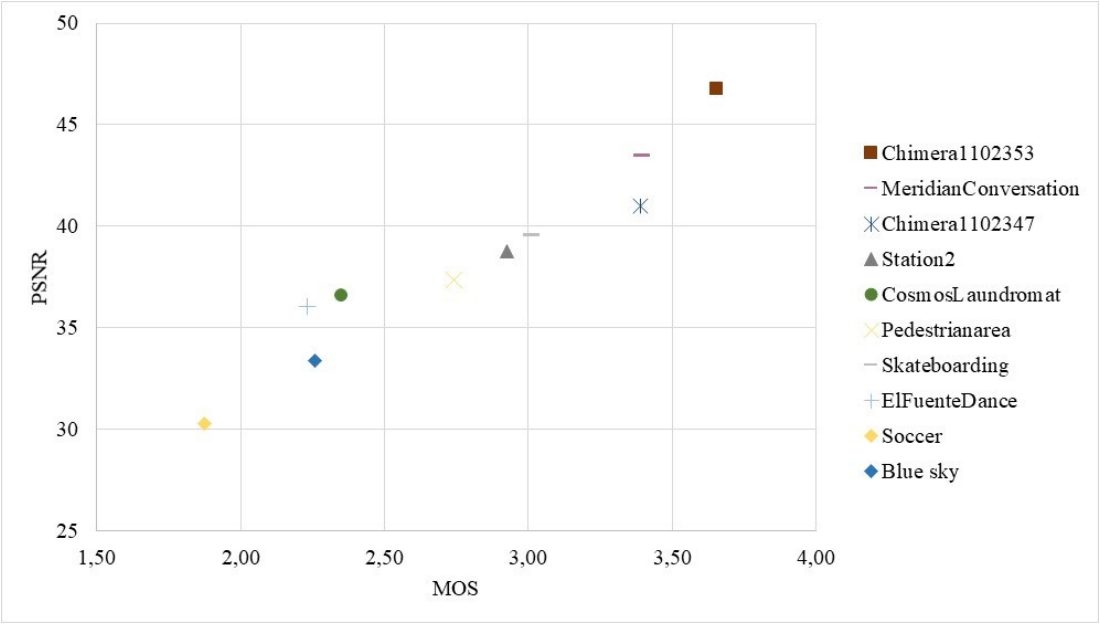
MOS rezultati za videosignale C53, CL i SO, prikazani na slici 3.15, potvrđuju da dolazi do preklapanja krivulja. Za CL i SO videosignale može se vidjeti da pri nižim kodnim brzinama vrijednosti MOS-a, kao i SSIM-a mogu biti veće za nižu prostornu rezoluciju. Videosignal C53 ima mnogo niže MOS vrijednosti na 640 x 360 nego na 1280 x 720 i za 1920 x 1080 prostornim rezolucijama, čak i na 600 kbit/s, jer se gubitak detalja uzrokovan smanjenjem prostorne rezolucije ne može prikriti zbog male prostorne i vremenske aktivnosti videosadržaja. Na slikama 3.16. do 3.19. prikazani su dijagrami koji opisuju ovisnost objektivnih metoda za ocjenu kvalitete PSNR, SSIM, VQM i VSNR i srenje vrijednosti subjektivne ocjene MOS. Iz prikazanih slika može se vidjeti da se povećanjem prostorne i vremenske aktivnosti videosadržaja, povećava i MOS vrijednost te da MOS i objektivne metode za ocjenu kvalitete videosignala imaju u pravilu linearnu ovisnost ako se uzmu u obzir prostorna i vremenska aktivnost videosadržaja.



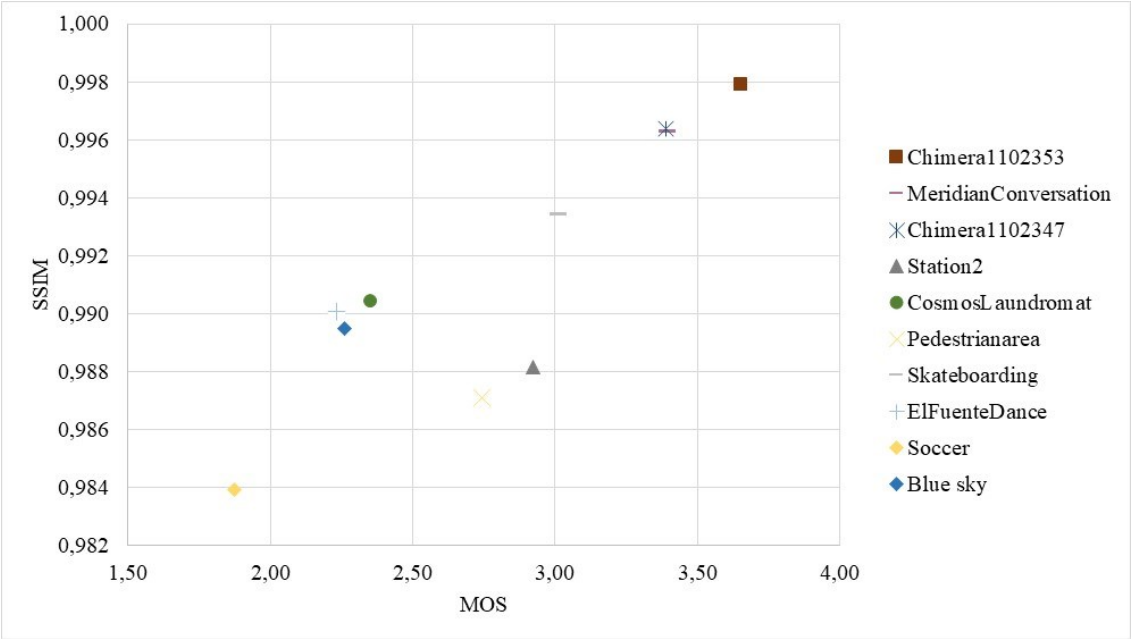
Slika 3.14. SSIM vrijednosti za tri prostorne rezolucije za videosignale *Chimera1102353* (C53), *Cosmos Laundromat* (CL) i *Soccer* (SO)



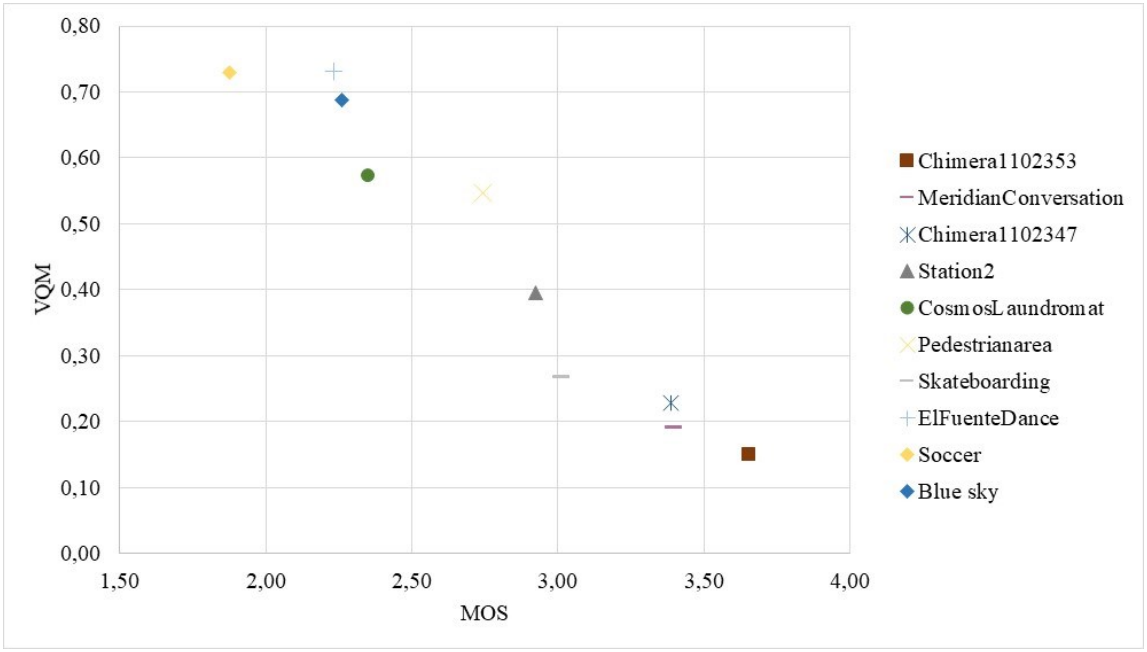
Slika 3.15. MOS vrijednosti za tri prostorne rezolucije za videosignale *Chimera1102353* (C53), *Cosmos Laundromat* (CL) i *Soccer* (SO)



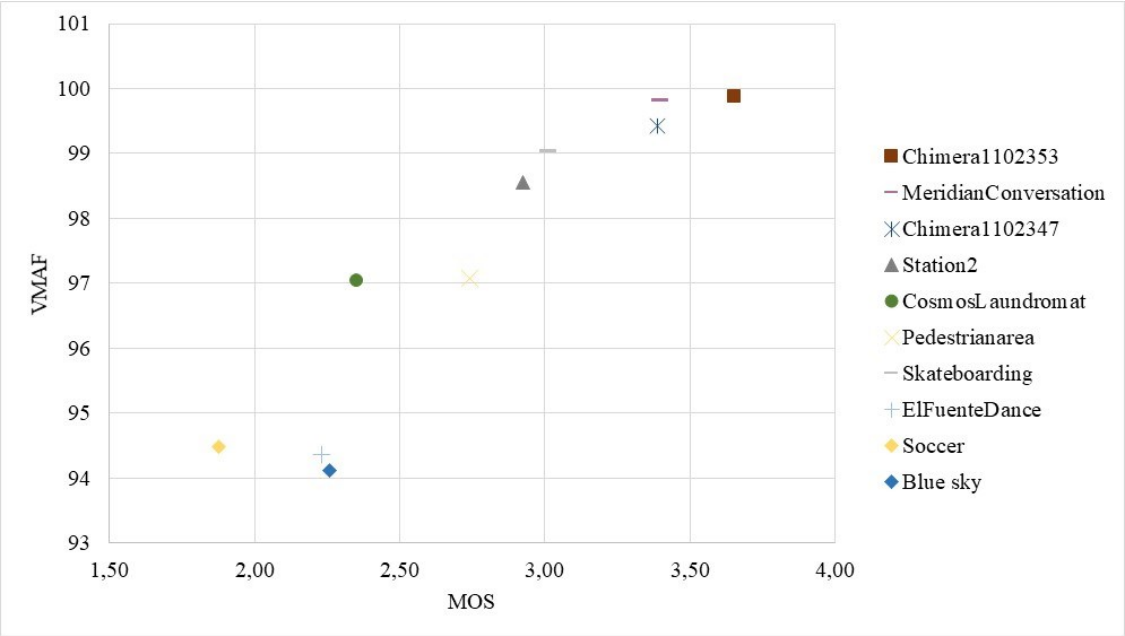
Slika 3.16. Odnos vrijednosti MOS i PSNR za sve videosignale korištene u ispitivanju



Slika 3.17. Odnos vrijednosti MOS i SSIM za sve videosignale korištene u ispitivanju



Slika 3.18. Odnos vrijednosti MOS i VQM za sve videosignale korištene u ispitivanju



Slika 3.19. Odnos vrijednosti MOS i VMAF za sve videosignale korištene u ispitivanju

4. METODA ZA ODABIR OPTIMALNIH RAZINA KVALITETE U POSTUPKU KODIRANJA I SEGMENTACIJE VIDEOSIGNALA

Dostupna istraživanja vezana uz MPEG DASH normu uglavnom su usredotočena na poboljšanje kvalitete korisničkog iskustva unapređenjem algoritama za prilagodljivo videostrujanje. Postoji nekoliko istraživanja koje ističu činjenicu da na logiku algoritama za prilagodljivo videostrujanje utječe i odabir skupova reprezentacija i parametara za kodiranje videosignala, posebno kad se algoritmi koriste za strujanje videosignala uživo [2, 100-102].

Iako postoje znanstveni radovi koji istražuju odabir parametara za skupove reprezentacija, većina rješenja je zaštićena autorskim pravima, ne uzima u obzir sadržaj videosignala i ne daje sveobuhvatnu metodologiju i njezin zapis koji se mogu primijeniti na druge kodeke i parametre kodera. U ovom je poglavlju dana sveobuhvatna analiza i metodologija za odabir optimalnih parametara kodiranja i segmentacije videosignala za primjenu u videostrujanju.

4.1. Odabir optimalnih mjesta promjene prostorne rezolucije

Prije razvoja same metode za odabir optimalnih parametara kodiranja i segmentacije videosignala za pojedine reprezentacije videosignala, bilo je potrebno prvo odrediti optimalna mjesta promjene prostorne rezolucije u ovisnosti o prostornoj i vremenskoj aktivnosti videosadržaja. U ovom poglavlju bit će dana analiza, metodologija i zapis postupka za odabir optimalnih točaka promjene prostorne rezolucije (engl. *spatial resolution* - SR) u ovisnosti o prostornoj i vremenskoj aktivnosti sadržaja i prijenosnim brzinama (engl. *bitrate* - BR).

4.1.1. Dostupna istraživanja

Postoji nekoliko pristupa za odabir skupa reprezentacija koji su već prisutni u dostupnim istraživanjima. Problem optimalnog skupa reprezentacija istražen je u [3, 103]. U [103] problem optimizacije usmjeren je na VQM objektivnu metodu za ocjenu kvalitete videosignala i sadržaj koji je podijeljen na sport, animirani film, dokumentarni film i film. Reprezentacije se odabiru u ovisnosti o vrsti videosadržaja, korisničkih postavki i mrežnih karakteristika koje se koriste kao ulazni parametri integriranog linearnog programa (engl. *Integral Linear Program* - ILP). Razvijeni ILP korišten je za određivanje reprezentacija kako bi se poboljšalo zadovoljstvo korisnika. ILP se temelji na mrežnim postavkama i postavkama korisničke aplikacije, a uzima u obzir vrstu videosadržaja, dinamiku mreže i karakteristike korisničke populacije. Iako ovo rješenje ostvarenom kvalitetom videosignala nadmašuje do tada korištene skupove reprezentacija (prema preporukama pružatelja usluga), nedostatak ovog rješenja je što koristi puno računalnih resursa, a

sadržaj je podijeljen u kategorije kao što su sport, animirani film, dokumentarni film i film što ne daje odgovarajuće informacije vezane uz aktivnost sadržaja ili njegovu učinkovitost kodiranja. Također, parametri kodiranja poput parametra kvantizacije (engl. *quantization parameter* - QP) nisu navedeni u istraživanju u kojem je opisana predložena metoda [3].

Kao što je istaknuto u istraživanju vezanom uz bazu videosignala opisanu u [104], dio dostupnih istraživanja kombinira različite preporuke pružatelja usluga, ali ima i istraživanja koja pokušavaju uzeti u obzir i složenost kodiranja. Na temelju ostvarenih prijenosnih brzina za svaki sadržaj i izračunatih vrijednosti VMAF objektivne metode za ocjenu kvalitete videosignala, autori [72] odabiru reprezentacije razmaknute za jednaku vrijednost VMAF-a. Mjera složenosti kodiranja sadržaja korištena je za određivanje raspona mogućih prijenosna brzina, a VMAF za podjednaku raspodjelu točaka prijenosne brzine uzimajući u obzir broj reprezentacija. Iako ovo istraživanje pruža veliko poboljšanje s obzirom da uzima u obzir sadržaj videosignala analizom ostvarene prijenosne brzine, nisu dane informacije potrebne za reprodukciju rezultata kao što su popis odabranih reprezentacija i njihovi parametri kodiranja. VMAF se također koristi za rješavanje problema optimizacije broja i parametara skupa reprezentacija u [105]. Raspodjela korisnika i vjerojatnost gledanja uzeti su u obzir prilikom rješavanja problema optimizacije u promjenjivim mrežnim uvjetima za videosignale s vidnim poljem od 360°. Iako predloženo rješenje uključuje potrebne zapise metode, ne uzima u obzir sadržaj videosignala i razvijeno je za prijenos videosignala s vidnim poljem od 360° gdje se uređaj za strujanje videosignala nalazi na glavi korisnika.

Sljedeće dostupno rješenje problema optimizacije zasnovano je na krivuljama ovisnosti prijenosne brzine i kvalitete videosignala (engl. *rate-quality* - RQ) [6, 106]. RQ krivulje određuju se na osnovu rezultata ostvarenih probnim kodiranjem pomoću različitih prostornih rezolucija i prijenosnih brzina za svaki videosignal i izračunavanjem PSNR vrijednosti [106]. Kodne brzine se u slučaju predložene metode odabiru pomoću problema optimizacije ograničenja (engl. *constraint optimization problem*) koji uzima u obzir raspodjelu veličine zaslona uređaja odnosno aplikacije koja se koristi za prikazivanje videosignala i dostupnu propusnost na korisničkoj strani aplikacije. Završni RQ model aproksimacija je linearne funkcije koja povezuje RQ točke. Analiza složenosti kodiranja videosignala s RQ krivuljama određenim pomoću PSNR-a također je korištena u [6] za određivanje optimalnog skupa reprezentacija. Prijenosna brzina svakog pojedinog dijela videosignala izmjerena je nakon kodiranja u više prolaza (engl. *multi-pass encoding*) uz postavljeni CRF. Iako koristi više računalne snage, ova vrsta postupka kodiranja osigurava poboljšanja u najnižoj mogućoj kvaliteti promatranog videosignala. Oba rješenja

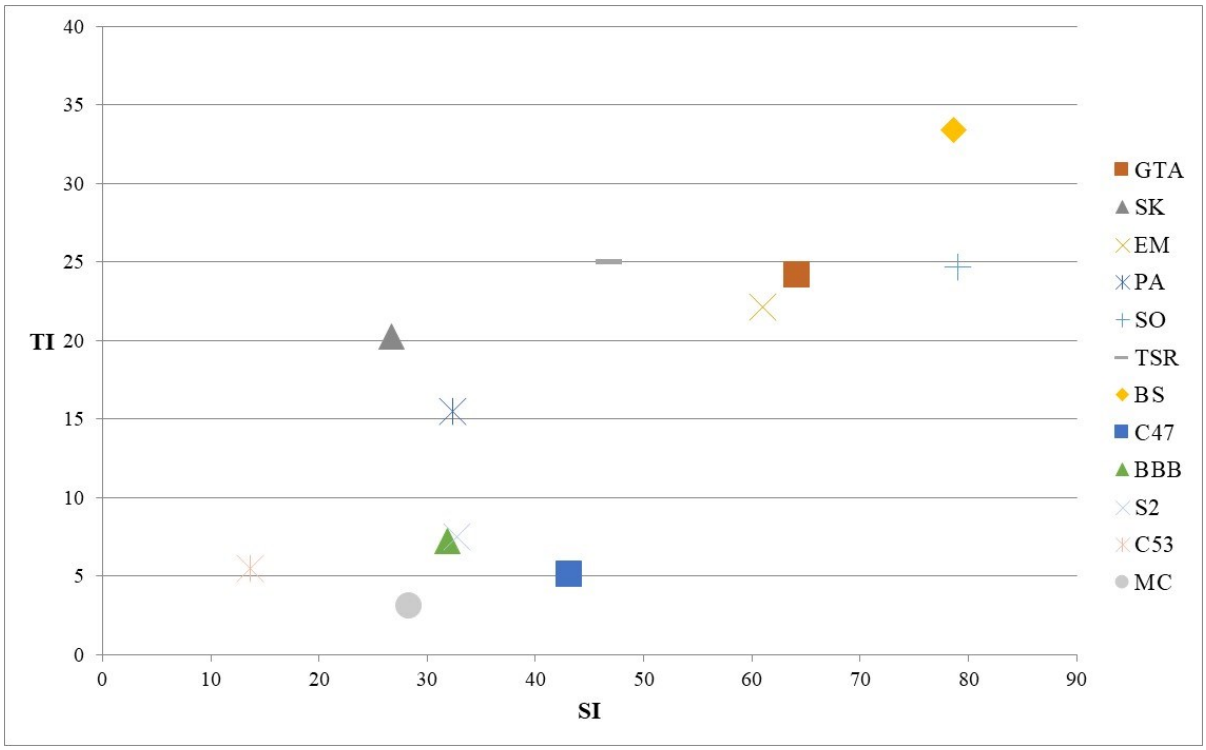
temeljena na PSNR-u koriste puno računalnih resursa zbog probnog kodiranja svakog videosignala prije određivanja optimalnog skupa reprezentacija.

Sljedeće predloženo rješenje problema optimizacije zasnovano je na proračunu srednje kvadratne pogreške (MSE) videosignala nakon probnog kodiranja i atributima kao što su stupanj izobličenja videosignala, složenost kodiranja i prijenosna brzina koji se koriste kao ulazni parametri u mehanizmu kontrole prijenosne brzine kako bi se izobličenja videosignala koja se mogu pojaviti na korisničkoj strani smanjila na minimum. Ovo rješenje postiže bolje rezultate u odnosu na ILP u slučajevima kada se koriste aplikacije osjetljive na početna kašnjenja i zastoje. Iako ovo rješenje opisuje metodu za kodiranje i odabir optimalnih parametara za reprezentacije, nejasno je kako odrediti broj reprezentacija za određeni videosignal [107].

Iz dostupnog pregleda može se zaključiti da je većina dostupnih rješenja zaštićena autorskim pravima i/ili ne daju sve potrebne podatke za reprodukciju. Također, neka od spomenutih rješenja ne uzimaju u obzir videosadržaj. Većina trenutno dostupnih rješenja koristi računalstvo u oblaku, stoga nisu ekonomične ili zahtijevaju veliku računalnu snagu.

4.1.2. Razvoj postupka za odabir optimalnih kodnih brzina za promjenu prostorne rezolucije

Analiza rezultata objektivnih metrika kao i MOS rezultata za različite prostorne rezolucije pokazala je da se na određenim kodnim brzinama bolja kvaliteta videosignla postiže na nižoj rezoluciji te da ta kodna brzina nije jednaka za sve videosignale korištene u analizi. S obzirom da je pokazana jasna ovisnost ostvarene kvalitete i kompleksnosti videosadržaja, odnosno vrijednosti SI i TI parametara videosignala, u cilju razvoja metode za odabir optimalnih kodnih brzina za promjenu prostorne rezolucije napravljena je detaljna analiza na 10 videosignala različite razine kompleksnosti iskazane kroz veliki raspon vrijednosti parametra SITI. Sljedeći videosignali odabrane su za potrebe razvoja metode: *Chimera1102353* (C53), *Meridian Conversatio*n (MC), *Chimera1102347* (C47), *Station2* (S2), *Pedestrian Area* (PA), *Skateboarding* (SK), *Tears Of Steel Robot* (T53) (EM), *Grand Theft Auto* (GTA), *Soccer* (SO) i *Blue Sky* (BS). Nadalje, videosignal *Big Buck Bunny* (BBB) korišten je isključivo za vrednovanje predložene metode [4, 59, 72]. Vrijednosti SI i TI za sve spomenute videosignale prikazane su na slici 4.1. Videosignali odabrani su kako bi se pokrile razne vrste videosadržaja i složenost videosignala. Svi korišteni videosignali imaju vremensku rezoluciju 24 slika po sekundi.



Slika 4.1. Prostorna i vremenska informacija videosignala korištenih u modeliranju

Sljedeći je korak bio odabir prostornih rezolucija za reprezentacije, zatim skaliranje videosignala s originalne rezolucije 1920x1080 na svaku od odabranih nižih prostornih rezolucija te kodiranje rezultirajućih videosignala na određenim kodnim brzinama. Početni opseg ciljanih kodnih brzina od 50 kbit/s do 8 Mbit/s kao i prostorne rezolucije odabrane su prema dostupnoj bazi videosignala kako bi se mogla kasnije napravili usporedba segmentacije prema predloženoj metodi i segmentacije dostupne u [4] (dalje u tekstu će se koristiti naziv: Lederer segmentacija). U svrhu ispitivanja korištene su sljedeće prostorne rezolucije: 320x240 (240p), 480x360 (360p), 854x480 (480p), 1280x720 (720p) i 1920x1080 (1080p). Prostorne rezolucije 240p i 360p često se koriste na mobilnim uređajima, dok su preostale tri prostorne rezolucije preuzete iz preporuke pružatelja usluge strujanja videosignala (YouTube). Svi videosignali kodirani su na odabranim prostornim rezolucijama u .y4m formatu. Besplatni program x264 [108] korišten je za kodiranje videosignala na odabranim prostornim rezolucijama i s 32 različite kodne brzine. Videosignali su kodirani uzimajući u obzir GOP i s trajanjem segmenata od dvije, šest i deset sekundi. Slijedi linija koda korištena za kodiranje na odabranim kodnim brzinama:

x264.exe --output big_buck_bunny_240p24_50_2.264 --fps 24 --preset slow --prijenosna brzina 50 --vbv-maxrate 50 --vbv-bufsize 100 --min-keyint 48 --keyint 48 --scenecut 0 --no-scenecut --pass 1 big_buck_bunny_240p24.y4m

Kodiranje je izvršeno na način da se *I* slika pojavljuje na početku svakog videosegmenta što znači da ako je trajanje segmenta 6 sekundi, a vremenska rezolucija 24 slike u sekundi, parametar --*keyint* koji određuje mjesto *I* slike bit će postavljen na vrijednost umnoška duljine trajanja videosegementa i vremenske rezolucije odnosno 96. Ostali parametri kodiranja prikazani su u tablici 4.1. Format kodiranih videosignal je .264.

Tablica 4.1. Parametri kodiranja videosignala

Naziv parametra	**Vrijednost**
Brzina kodera	polako
Odluka o prilagodljivom ključnom kadru	onemogućena
Maksimalna brzina verifikatora međuspremnika	dvostruka vrijednost prijenosne brzine
Veličina međuspremnika verifikatora	četverostruka vrijednost prijenosne brzine
CRF	23
Prolaz (eng. *pass*)	1
Sažimanje krivulje kvantizatora	0.6
Vrsta kodiranja	CABAC

Nakon kodiranja, besplatni program MP4Box [109] korišten je za pretvorbu svih videosignala u .mp4 format datoteke. Konačno, svi videosignali s prostornom rezolucijom manjom od 1080p skalirani su bilinearnom interpolacijom u programu FFmpeg na izvornu prostornu rezoluciju. Skaliranje se vrši zbog činjenice da se, bez obzira na promjenu prostorne rezolucije tijekom strujanja videosignala, gledatelju prikazuje videosignal u jednoj prostornoj rezoluciji koja obično ovisi o uređaju koji se koristi. Slijedi linija koda korištena za skaliranje na 1080p prostornu rezoluciju:

ffmpeg -i big_buck_bunny_240p24_50_2.mp4 -vf scale=1920x1080:flags=bilinear -c:v libx264 -preset slow big_buck_bunny_240p24_50_2_upscale.mp4

Kvaliteta kodiranih videosignala određena je pomoću SSIM objektivne metode za ocjenu kvalitete. SSIM je korišten za ocjenu kvalitete jer je istraživanje opisano u odjeljku 3.2.2.2 pokazalo da za odabrani skup objektivnih metrika za ocjenu kvalitete videa, SSIM postiže najbolju ukupnu korelaciju sa MOS vrijednostima u slučajevima kada su videosignali kodirani s različitim prostornim rezolucijama i različitim kodnim brzinama. SSIM vrijednosti za istraživanje predstavljeno u ovom radu izračunate su pomoću programa FFmpeg.

Slijedi linija koda korištena za računanje ocjene kvalitete videosignala pomoću SSIM-a:

ffmpeg -i big_buck_bunny_240p24_50_2_upscale.mp4 -i big_buck_bunny_1080p24.mp4-lavfissim="stats_file=big_buck_bunny_240p24_50_2_upscale_ssim.log" -f null –

4.1.2.1. Točke promjene prostorne rezolucija u ovisnosti o SSIM-u

Videosignali MC, C47, SK i EM odabrani su kao reprezentativni uzorak za prikaz rezultata ispitivanja. Po jedna slike svakog videosignala prikazana je na slici 4.2. Sva četiri videosignala odabrana su prema SI i TI (slika 4.1). MC i SK imaju sličan (nizak) SI, ali SK ima veću vrijednost TI. EM i SK imaju sličan (umjereni) TI, ali EM ima veću vrijednost SI. C47 i MC imaju sličan (nizak) TI, ali C47 ima veću vrijednost SI.



a)



b)



c)

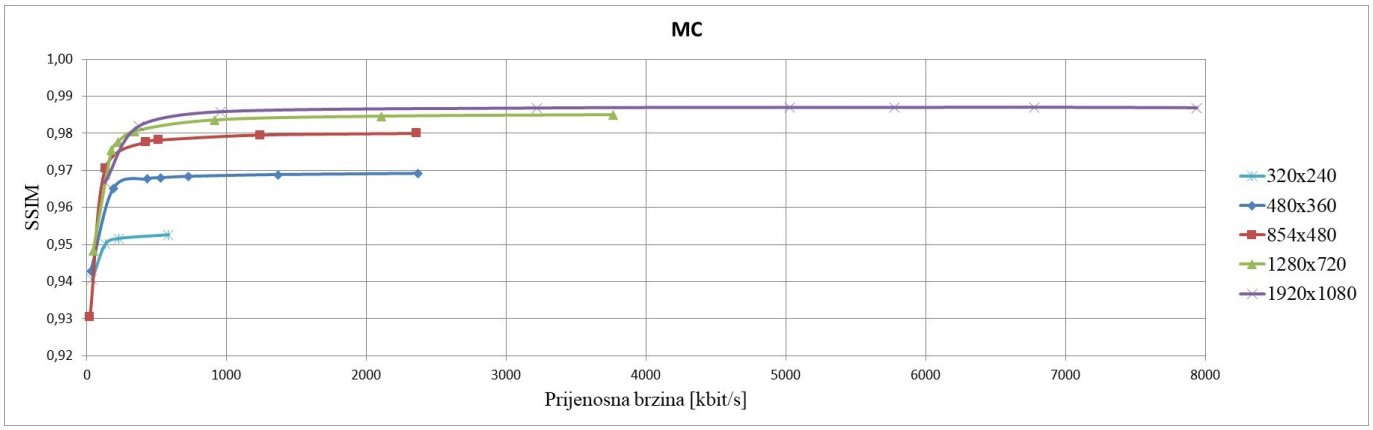


d)

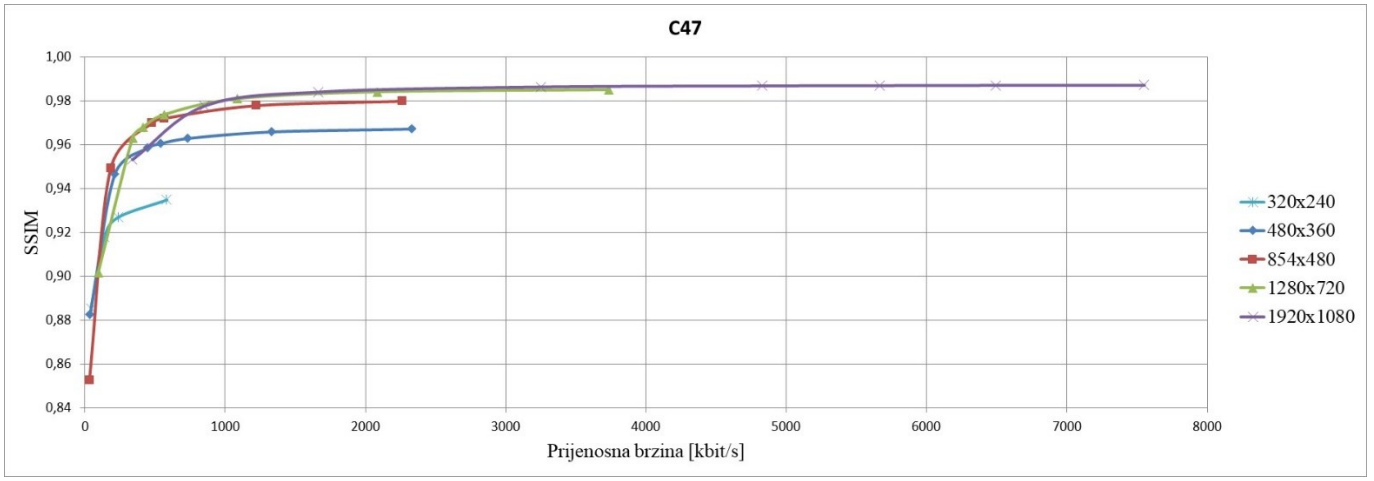
Slika 4.2. Slike iz videosignala: a) *Meridian Conversation* b) *Chimera1102347* c) *Skateborading* d) *El Fuente Mask*

Na slikama 4.3 do 4.6 prikazane su krivulje ovisnosti SSIM-a o prijenosnoj brzini za videosignale MC, C47, SK i EM. Oni potvrđuju rezultate iz 3.2.2.2 da postoje sjecišta između krivulja s različitim prostornim rezolucijama. Za istu postignutu prijenosnu brzinu, SSIM može biti veći za nižu prostornu rezolucija, stoga tu činjenicu treba uzeti u obzir pri odabiru odgovarajućih kodnih brzina i prostornih rezolucija za kodiranje videosignala prije postupka segmentacije. Iz slike 4.3 može se vidjeti da prostorna rezolucija od 480p postiže veći SSIM u

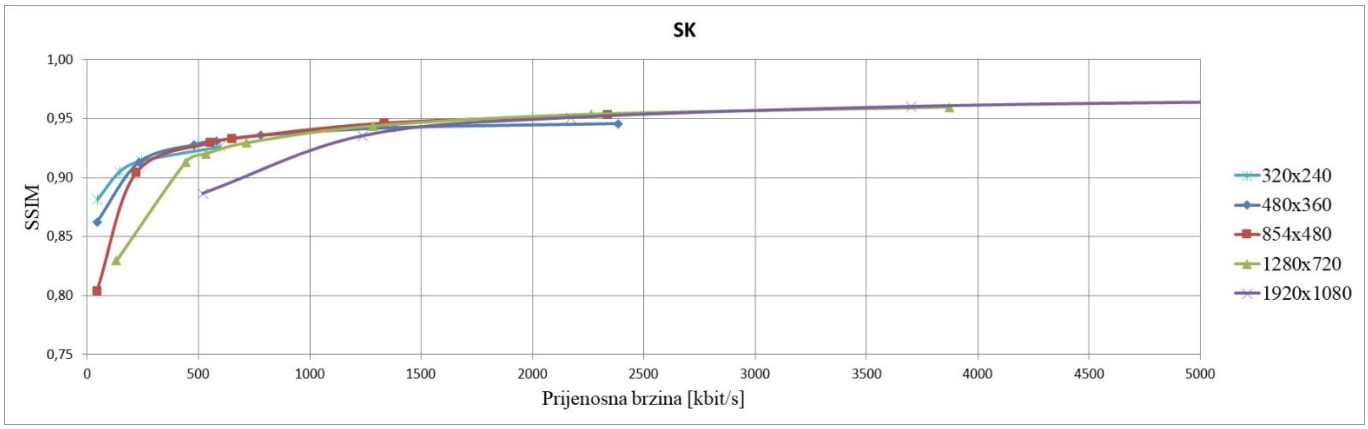
odnosu na 720p i 1080p kada je postignuta prijenosna brzina niža od 200 kbit/s. Razlika između najviše i najniže postignute SSIM vrijednosti manja je kada se koriste videosignale s malim SI i TI vrijednostima. Također, videosignali s višim SI i TI vrijednostima postižu sveukupno niže SSIM vrijednosti zbog činjenice da ih je teže kodirati na odabranim kodnim brzinama. Važno je uočiti i da se krivulja sijeku na različitim kodnim brzinama za različite sekvence i to u pravilu na višim brzinama za videosignale s većim vrijednostima SITI parametra.



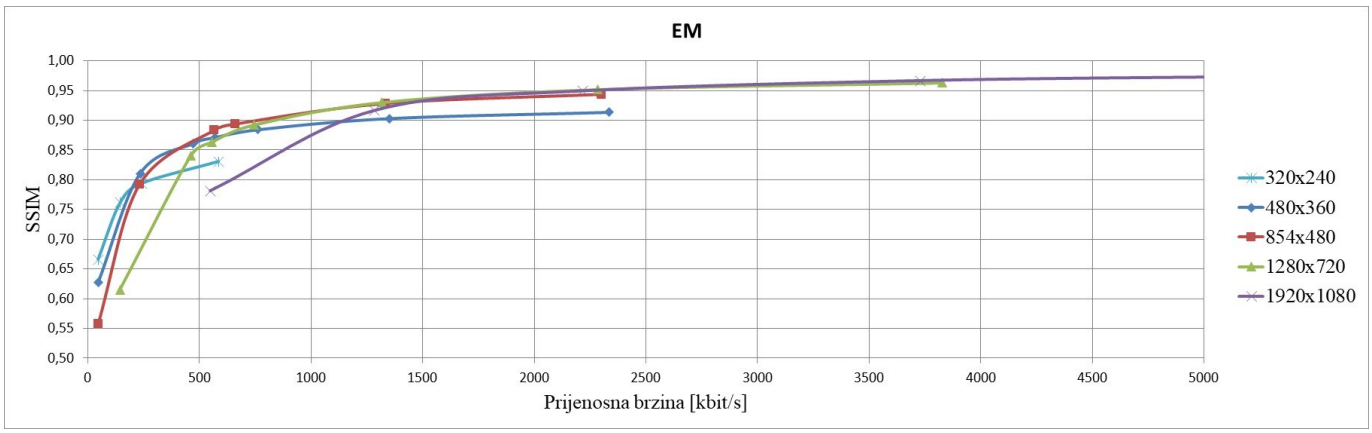
Slika 4.3. Krivulje ovisnosti SSIM-a o prijenosnoj brzini za *Meridian Conversation* videosignal kodiran na odabranim prostornim rezolucijama:240p, 360p, 480p, 720p i 1080p



Slika 4.4. Krivulje ovisnosti SSIM-a o prijenosnoj brzini za *Chimera1102347* videosignal kodiran na odabranim prostornim rezolucijama:240p, 360p, 480p, 720p i 1080p



Slika 4.5. Krivulje ovisnosti SSIM-a o prijenosnoj brzini za *Skateborading* videosignal kodiran na odabranim prostornim rezolucijama:240p, 360p, 480p, 720p i 1080p



Slika 4.6. Krivulje ovisnosti SSIM-a o prijenosnoj brzini za *El Fuente Mask* videosignal kodiran na odabranim prostornim rezolucijama:240p, 360p, 480p, 720p i 1080p

4.1.2.2. Funkcijska ovisnost prijenosne brzine o prostornoj rezoluciji i SITI-ju

Nakon analize krivulja ovisnosti SSIM vrijednosti o prijenosnoj brzini za različite prostorne rezolucije, određene su optimalne točke promjene prostorne rezolucije na osnovu točaka sjecišta krivulja za različite prostorne rezolucije. Analiza rezultata pokazala je da vrijednosti prijenosne kodne brzina gdje je promjena prostorne rezolucije optimalna (dalje u tekstu zvat će se optimalne prijenosne brzine za prebacivanje prostorne rezolucije i označavat će se s BR) ovise o sadržaju videosignala, odnosno povećavaju se porastom vrijednosti SI i TI za sve videosignale. Najveća korelacija postignuta je između optimalnih prijenosne brzine za promjenu prostorne rezolucije i umnoška vrijednosti SI i TI, odnosno parametra SITI.

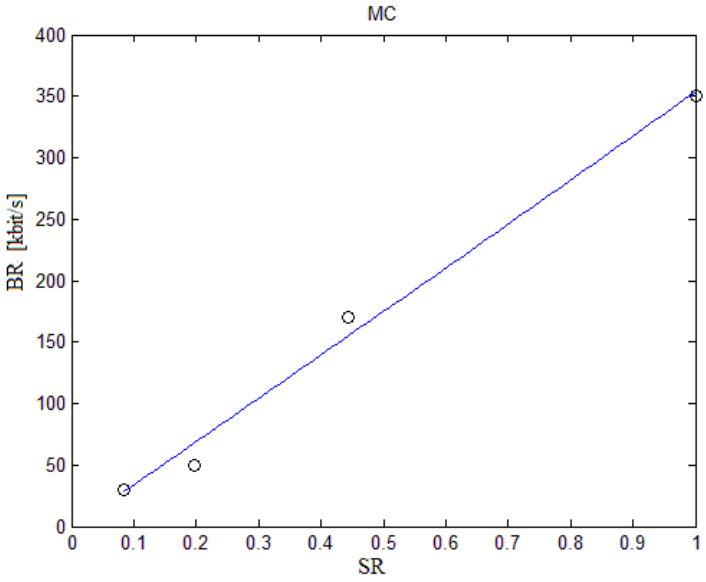
Optimalne točke promjene prostorne rezolucije korištene su za pronalaženje krivulja, a time i funkcijske ovisnosti između optimalnih prijenosnih brzina BR i SITI vrijednosti za svaki videosignal. Prvi korak je određivanje funkcija koje opisuju krivulje koje povezuju optimalne

točke promjene prostorne rezolucije za pojedini videosignal što daje vezu između optimalnih prijenosnih brzina BR i prostorne rezolucije SR (na koju treba podići videosignal za kodiranje brzinama većim ili jednakim BR). Prostorna rezolucija SR je pri tome iskazana relativno u odnosu na najveću korištenu rezoluciju 1920x1080 prema tablici 4.3 (dalje u tekstu za SR koristit će se izraz relativna prostorna rezolucija). Ovaj pristup je primijenjen jer omogućuje širu upotrebu predložene metode, odnosno njenu primjenu i za prostorne rezolucije koje nisu uključene u modeliranje.

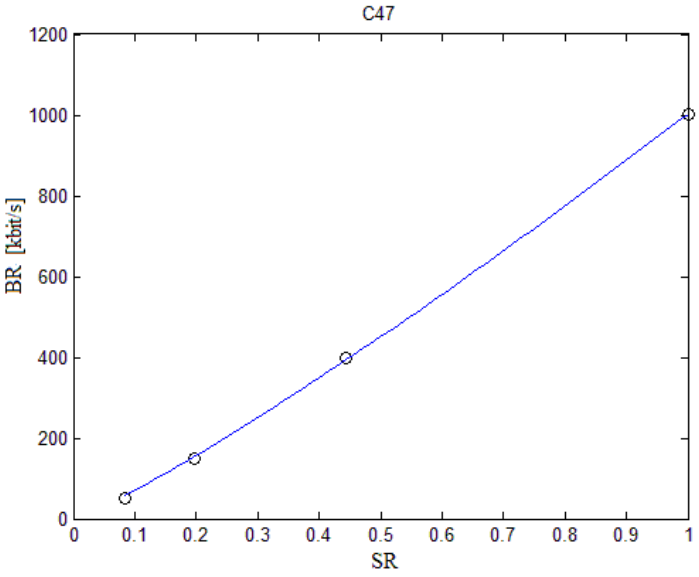
Tablica 4.3. Relativna prostorna rezolucija SR izražena kao omjer broja elemanta slike za danu prostorne rezolucija i broja elemenata slike za rezoluciju 1080p

Prostorna rezolucija	**Broj elemenata jedne slike NP (engl. *Number of Pixels*)**	**Omjer prostorne rezolucije i rezolucije 1080p SR=NP/(1920x1080)**
320x240	76800	0.037
480x360	172800	0.083
854x480	409920	0.198
1280x720	921600	0.444
1920x1080	2073600	1.000

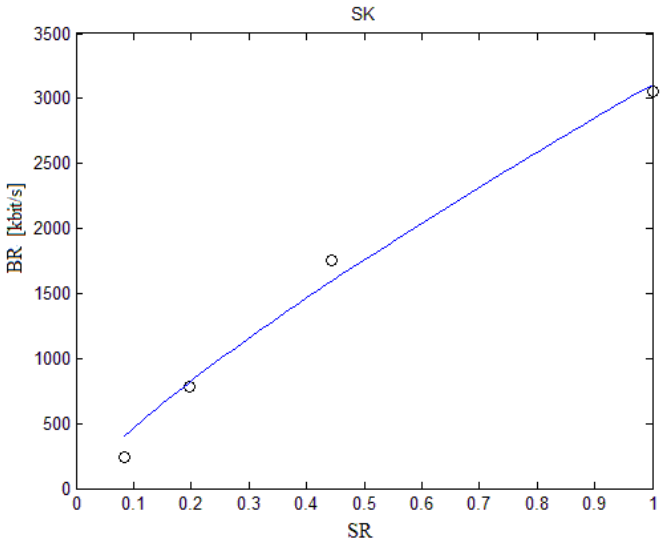
Slike 4. 7 do 4.10 prikazuju krivulje BR-SR za MC, C47, SK i EM videosignale. Određivanje koeficijenata funkcija koje opisuju ove krivulje izvršeno je u programu Matlab pomoću funkcije *lscurvefit* koja odabranu funkciju modelira kao nelinearnu funkciju, a koeficijente funkcije koja nabolje odgovara empirijskim rezultatima određuje metodom najmanjih kvadrata.



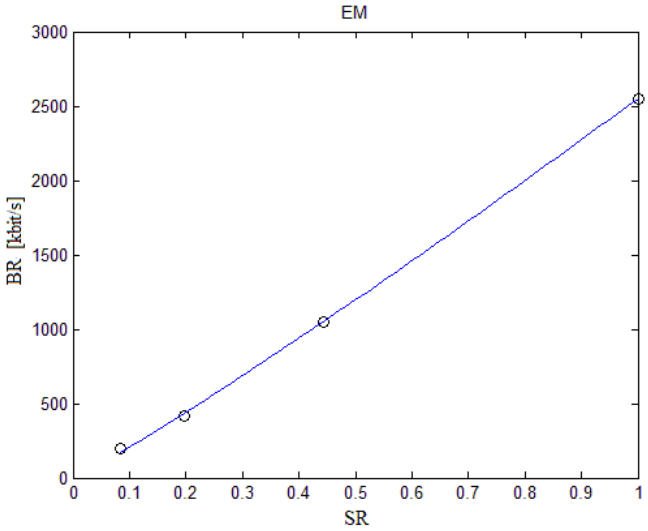
Slika 4.7. Krivulja ovisnosti optimalnih prijenosnih brzina BR (za promjenu prostorne rezolucije) o relativnoj prostornoj rezoluciji SR za videosignal *Meridian Conversation*



Slika 4.8. Krivulja ovisnosti optimalnih prijenosnih brzina BR (za promjenu prostorne rezolucije) o relativnoj prostornoj rezoluciji SR za videosignal *Chimera1102347*



Slika 4.9. Krivulja ovisnosti optimalnih prijenosnih brzina BR (za promjenu prostorne rezolucije) o relativnoj prostornoj rezoluciji SR za videosignal *Skateboarding*



Slika 4.10. Krivulja ovisnosti optimalnih prijenosnih brzina BR (za promjenu prostorne rezolucije) o relativnoj prostornoj rezoluciji SR za videosignal *El Fuente Mask*

Na temelju krivulja ovisnosti optimalnih prijenosnih brzina BR o relativnoj prostornoj rezoluciji SR za sve videosignale, odabrana je eksponencijalna funkcija oblika (4-1) za modeliranje ovisnosti BR o SR.

$$BR = A * SR^B \tag{4-1}$$

A i *B* su koeficijenti određeni *lscurvefit* funkcijom tako da dobivena funkcija prolazi najbliže empirijski dobivenim optimalnim točkama za promjenu rezolucije u smislu najmanjih kvadrata te su njihove vrijednosti za sve korištene videosignale prikazane u tablici 4.2. Pri tome su vrijednosti

A i B određene za BR iskazan u kbit/s. Eksponencijalna funkcija odabrana je zbog činjenice da je oblik BR-SR krivulja bio linearan, konkavan ili konveksan, ovisno o videosignalu. Uz primjenu eksponencijalne funkcije ostvarena je visoka korelacija vrijednosti izračunatih pomoću izraza (4-1) i izmjerenih vrijednosti (PLCC za sve videosignale iznosi 0,998), iz čega se može zaključiti da je izbor funkcije za vezu BR i SR bio dobar. Za usporedbu, da je za modeliranje odabrana linearna funkcija, srednja vrijednost PLCC-a bila bi 0,987.

Tablica 4.2. Vrijednosti koeficijenata *A* i *B* određene *lscurvefit* funkcijom za sve videosignale

Naziv videosignala	**A**	**B**	**SITI**
C53	543,52	0,96	75,07
MC	353,21	1,02	87,86
C47	1001,54	1,15	218,36
S2	899,63	1,31	245,40
PA	2392,48	1,38	500,11
SK	3103,87	0,82	540,48
SO	2084,54	1,08	1953,52
BS	2019,74	1,37	2627,31
GTA	4007,53	1,19	861,65
EM	2548,40	1,09	1357,14
TSR	2059,31	0,94	995,02

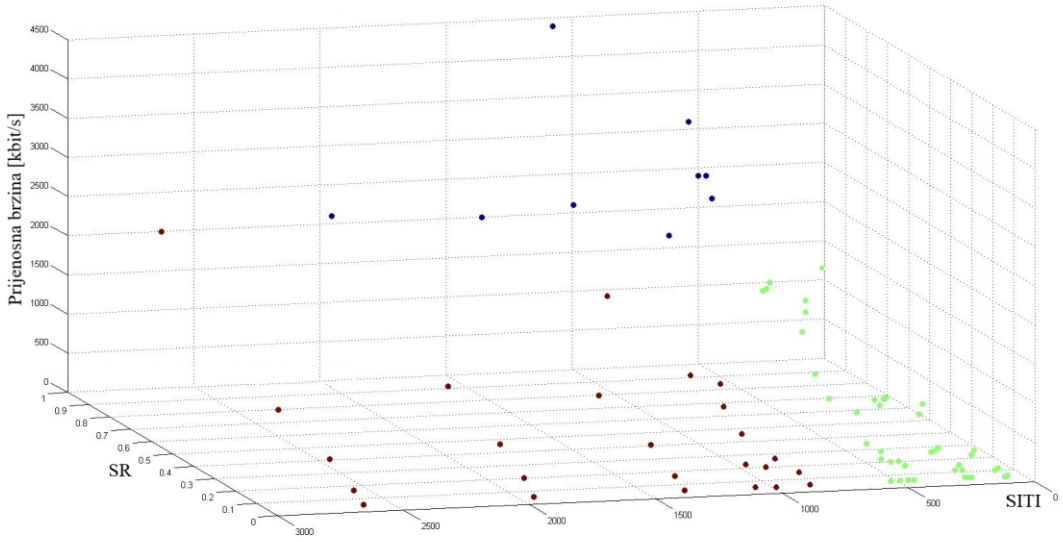
Kako bi izraz (4-1) bio primjenjiv za proizvoljne videosignale, provedena je daljnja analiza funcijske veze vrijednosti koeficijenata *A* i *B* i vrijednosti SITI parametra.

4.1.2.3. Ugrožđavanje točaka promjene prostorne rezolucije

Odnos između optimalne prijenosne brzine BR i parametra SITI ima različit karakter za različite vrijednosti SITI, stoga se koristio postupak ugrožđavanja (engl. *clustering*) optimalnih točaka promjene prostorne rezolucije kako bi se olakšalo određivanje oblika funkcija koje će se koristiti u razvoju metode za odabir optimalnih mjesta promjene prostorne rezolucije.

Slika 4.11. prikazuje rezultat ugrožđavanja svih očitanih optimalnih točaka promjene prostorne rezolucije. Ugrožđavanje je izvršeno pomoću Lloydovog algoritma (*k-means* funkcija u Matlabu) [110]. Lloydov algoritam koristi višestruke iteracije prilikom kojih svaku točku dodjeljuje jednom od *k* grozdova. Grozdove, čiji broj korisnik treba unaprijed odrediti, definiraju centroidi. Nakon

definiranja početnih centroidnih točaka, algoritam izračunava udaljenosti između svake točke i centroida i dodjeljuje točku jednom od centroida. Nakon nekoliko pokusa, broj centroida postavljen je na tri.



Slika 4.11. Rezultat ugrožđavanja optimalnih točaka promjene prostorne rezolucije određenih pomoću mjerenja za sve odabrane videosignale

Uzimajući u obzir da je većina točaka promjene prostorne rezolucije (točke prebacivanja) dodijeljena dvjema centroidima, odlučeno je da se nastavi s dva grozda. Točke prebacivanja iz trećeg grozda dodijeljeni su jednom od dva preostala grozda na temelju većine broja točaka koji pripadaju određenom grozdu, na primjer, ako su točke iz jednog videosignala za prostorne rezolucije 240p, 360p, 480p i 720p dodijeljene prvom grozdu, preostala točka za 1080p prostornu rezoluciju također je dodijeljena prvom grozdu. Uzimajući u obzir da su točke iz trećeg grozda uglavnom točke prebacivanja između prostornih rezolucija 720p i 1080p, dodijeljene su jednom od dva preostala grozda kako bi se izbjegla zasebna metoda za prostornu rezoluciju 1080p, tj. da bi se metoda učinila primjenjivim na sve prostorne rezolucije koje se obično koriste u prilagodljivom videostrujanju. Analizom ugrožđavanja (slika 4.11) može se zaključiti da se podaci za videosignale sa SITI-jem jednakim ili manjim od 500 nalaze u prvom grozdu, a podaci za videosignale sa SITI-jem većim od 500 u drugom grozdu.

Uzimajući u obzir da postoje dvije skupine videosignala s različitim ovisnostima prostornih rezolucija i optimalnih vrijednosti prijenosnih brzina o parametru SITI, funkcijske ovisnosti koeficijenata *A* i *B* o SITI-ju određene su odvojeno za videosignale sa SITI-jem jednakim ili

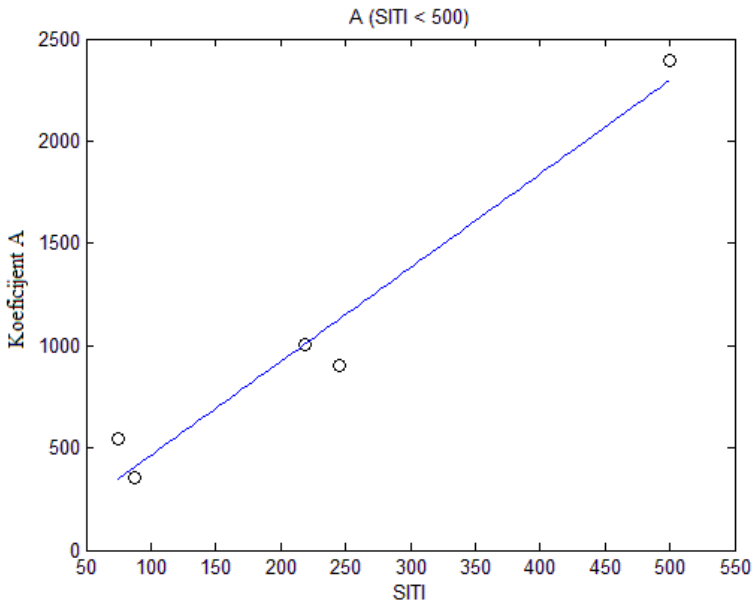
manjim od 500 i za one sa SITI-jem većim od 500. Slike 4.12. i 4.13. prikazuju krivulje ovisnosti koeficijenta A o SITI-ju za oba grozda. Istraživanjem je utvrđeno da je za opisivanje fukcije A'(SITI) za videosignale sa SITI-jem jednakim ili nižim od 500 optimalno koristiti linearnu funkciju, dok je za videosignale sa SITI-jem većim od 500 optimalno koristiti eksponencijalnu funkciju. Funkcija koja opisuje ovisnost A'(SITI) dana je izrazom (4-2):

$$A'(SITI) = C * SITI + D + E * \exp(F * SITI) \tag{4-2}$$

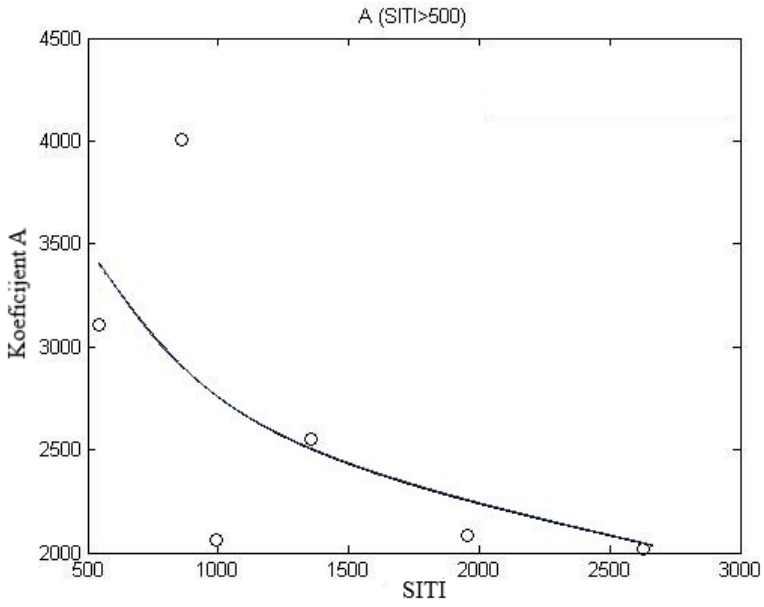
gdje su *E* i *F* jednaki nuli za SITI manji ili jednak 500, a *C* i *D* su jednaki nuli za SITI veći od 500.

Vrijednosti koeficijenata *C*, *D*, *E* i *F* izračunate pomoću *lscurvefit* funkcije prikazane su u tablici 4.4. PLCC vrijednost određena za *A'* i *A* za SITI niži od 500 iznosi 0,9798, a za SITI veći od 500 iznosi 0,6458. PLCC vrijednost određena za *B'* i *B* za SITI niži od 500 iznosi 0,9585, a za SITI veći od 500 iznosi 0,7708. Može se primijetiti da je korelacija niža u slučaju kada se koriste videosignali sa SITI-jem većim od 500 što se može objasniti prijenosom nekoliko točaka prebacivanja prostorne rezolucije s trećeg grozda na drugi grozd (slika 4.13). Drugi razlog ove anomalije može se objasniti maskiranjem pogrešaka koje se javljaju u videosignalima s vrlo visokim SITI-jem pa se u nekim slučajevima točke promjene rezolucije mogu pojaviti pri nižim prijenosnim brzinama od očekivanih. Funkcijska ovisnost B'(SITI) za sve videosignale opisana je izrazom (4-3). Vrijednosti koeficijenata *G* i *H* izračunate pomoću *lscurvefit* funkcije prikazane su u tablici 4.4.

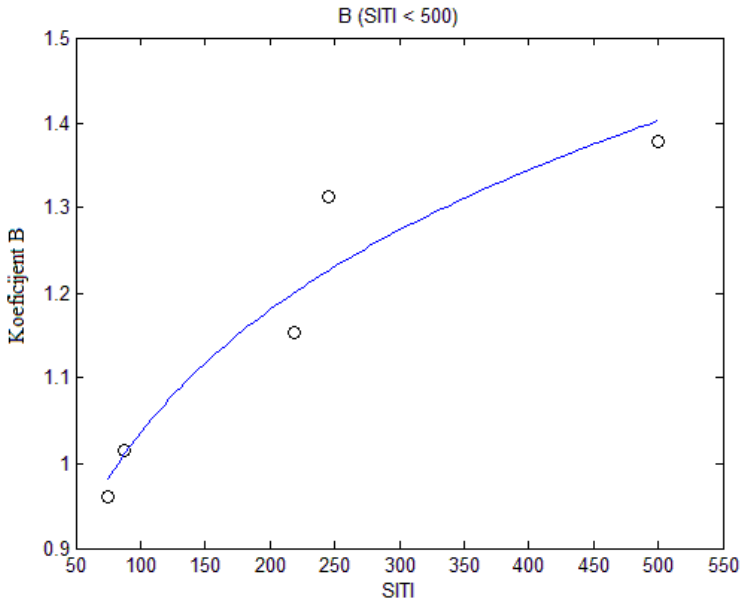
$$B'(SITI) = G * SITI^{H} \tag{4-3}$$



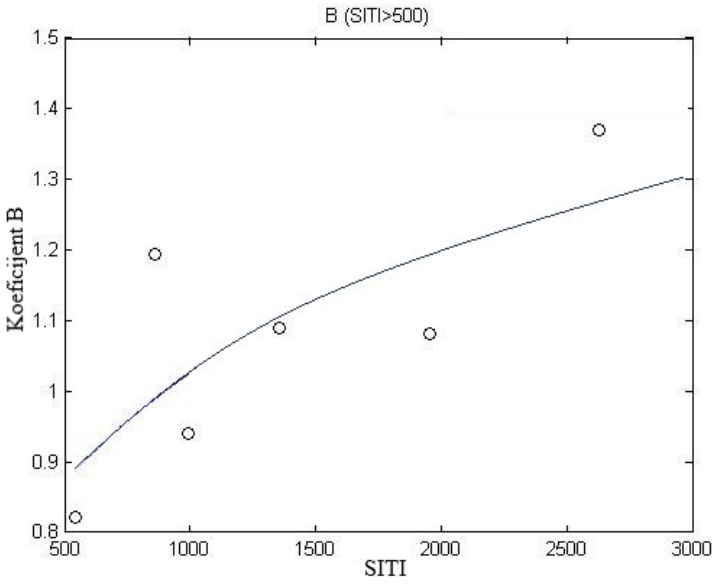
Slika 4.12. Krivulja ovisnosti koeficijenta *A* o SITI-ju za videosignale sa SITI ≤ 500



Slika 4.13. Krivulja ovisnosti koeficijenta *A* o SITI-ju za videosignale sa SITI > 500



Slika 4.14. Krivulja ovisnosti koeficijenta *B* o SITI-ju za videosignale sa sa SITI ≤ 500



Slika 4.15. Krivulja ovisnosti koeficijenta *B* o SITI-ju za videosignale sa SITI-jem SITI >500

Tablica 4.4. Vrijednosti koeficijenata *C*, *D, E, F, G* i *H*

	C	**D**	**E**	**F**	**G**	**H**
SITI≤500	4.582	5.421	0	0	0.435	0.188
SITI>500	0	0	27416.1	-0.332	0.198	0.238

Primjenom (4-2) i (4-3) dobije se izraz (4-4) koji je matematički zapis metode za odabir optimalnih prijenosnih brzina BR za promjenu rezolucije na relativnu prostornu rezoluciju SR za videosignal s prostorno-vremenskom informacijom SITI

$$BR(SR, SITI) = (C * SITI + D + E * exp(F * SITI)) * SR^{G*SITI^H} \quad (4\text{-}4)$$

S obzirom na to da je izraz (4-4) kontinuirana funkcija od SR, metoda odabira prostorne rezolucija prikladna je za izračunavanje optimalne prijenosne brzine BR i za prostorne rezolucija koje nisu korištene u procesu razvoja metode.

4.1.3. Vrednovanje predložene metode

Ispitivanje točnosti predložene metode za odabir optimalnih mjesta promjene prostorne rezolucije izvršeno je pomoću metoda statističke analize, zatim pomoću odabrane metode za subjektivno ocjenjivanje kvalitete videosignala i na kraju je metoda ispitana u stvarnim uvjetima strujanja videosignala.

4.1.3.1. Statistička analiza

Ispravnost predložene metode za odabir optimalnih mjesta prebacivanja prostorne rezolucije prvo je ispitana pomoću metoda statističke analize. Vrijednosti optimalnih prijenosnih brzina za svaki videosignal, za svaku prostornu rezoluciju određene su pomoću (4-4) i prikazane u tablici 4.5. Iz tablice 4.5. se može vidjeti da videosignali s višim SITI vrijednostima imaju i veće vrijednosti optimalne prijenosne brzine pri kojoj je potrebno prijeći na višu prostornu rezoluciju. Za videosignale s višim SITI-jem očekivano su veće optimalne prijenosne brzine na kojima treba povećati prostornu rezolucija kako bi se postigla najbolja moguća kvaliteta videosignala.

U tablicama 4.6. i 4.7. prikazane su vrijednosti razlike između izmjerenih vrijednosti prijenosne brzine pri kojoj je potrebno prijeći na višu prostornu rezoluciju i između vrijednosti procijenjenih predloženom metodom. U tablici 4.6. vrijednosti su dane u kbit/s, a u tablici 4.7. vrijednosti su dane u postocima. Iz obje tablice vidljivo je da je u 85% slučajeva razlika manja od 40%, a u svim se slučajevima veća razlika dogodila pri nižim prostornim rezolucijama i nižim optimalnim vrijednostima prijenosne brzine. Prosječna (apsolutna) razlika između procijenjene i izmjerene prijenosne brzine je 111,135 kbit/s odnosno 20,83 %.

Tablica 4.5. Vrijednosti optimalnih vrijednosti prijenosnih brzina procijenjenih predloženom metodom

	Optimalna prijenosna brzina u točki prebacivanja, BR [kbit/s]										
Relativna prostorna rezolucija, SR	C53	MC	C47	S2	PA	SK	SO	BS	GTA	EM	TSR
0.083	31	33	51	54	70	429	112	81	249	162	218
0.198	71	79	144	155	237	851	316	248	586	419	528
0.444	158	180	380	418	737	1619	837	706	1306	1025	1210
1.000	349	408	1006	1130	2297	3081	2221	2013	2913	2506	2778

Tablica 4.6. Razlika između izmjerenih optimalnih vrijednosti prijenosnih brzina i optimalnih vrijednosti prijenosnih brzina procijenjenih predloženom metodom

	Razlika izmjerene i procijenjene optimalne prijenosne brzine [kbit/s]											
Relativna prostorna rezolucija, SR	C53	MC	C47	S2	PA	SK	SO	BS	GTA	EM	TSR	**Srednja vrijednost apsolutne razlike [kbit/s]**
0.083	44	-3	-1	-4	130	-189	68	59	-49	38	-23	55.3
0.198	4	-29	6	-55	13	-71	104	112	-56	1	-118	51.7
0.444	112	-10	20	-108	13	141	-37	-156	254	25	-210	98.9
1.000	191	-58	-6	-230	103	-31	-121	27	1087	44	-728	238.7

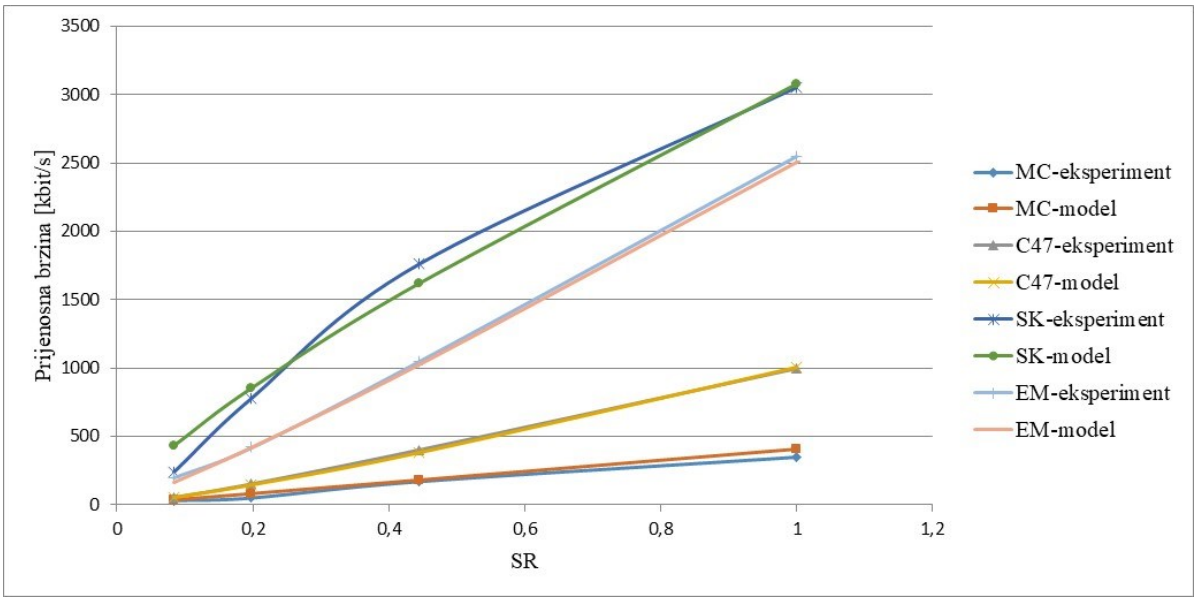
Tablica 4.7. Postotna razlika između izmjerenih optimalnih vrijednosti prijenosnih brzina i optimalnih vrijednosti prijenosnih brzina procijenjenih predloženom metodom

	Postotna razlika izmjerene i procijenjene optimalne prijenosne brzine [%]											
Relativna prostorna rezolucija, SR	C53	MC	C47	S2	PA	SK	SO	BS	GTA	EM	TSR	**Srednja vrijednost apsolutne razlike [%]**
0.083	59	-10	-2	-7	65	-79	38	42	-25	19	-12	32.5
0.198	5	-59	4	-55	5	-9	25	31	-10	0	-29	21.1
0.444	42	-6	5	-35	2	8	-5	-28	16	2	-21	15.5
1.000	35	-17	-1	-26	4	-1	-6	1	27	2	-35	14.2

Iako se razlika u postocima za najnižu prostornu rezolucija u nekim slučajevima čini velikom, važno je istaknuti da se optimalnu prijenosna brzina pri kojoj je potrebno prijeći na višu prostornu rezoluciju ne mora zaista koristiti kao prijenosna brzina neke reprezentacije. Važno je samo da se prilikom kodiranja brzinama koje su ispod točke prebacivanja (tj. niže su od optimalne prijenosne brzine za promjenu rezolucije) koristi niža prostorna rezolucija od SR, a kod kodiranja brzinama iznad točke prebacivanja prostorne rezolucije treba se se koristiti prostorna rezolucija jednaka ili viša od SR.

Također je potrebno uzeti u obzir da su kodne brzine najčešće nešto veće od ostvarenih prijenosnih brzina. Unatoč odstupanjima, može se reći da predložena metoda s prosječnom pogreškom procjene od 20,83 % uspješno predviđa točke prebacivanja prostorne rezolucije.

Na slici 4.16. prikazane su krivulje koje povezuju (BR,SR) točke dobivene mjerenjem i krivulje koje povezuju točke procijenjene predloženom metodom za videosignale MC, C47, SK i EM. Može se vidjeti da krivulje koje predstavljaju procijenjene podatke ne odstupaju značajno od onih dobivenih iz izvornih podataka. Isto se može vidjeti i iz tablice 4.8. Također, PLCC i RMSE izračunati su za sve prijenosne brzine prebacivanja prostorne rezolucije izračunate predloženom metodom i prijenosne brzine određene pomoću izmjerenih podataka. U velikom rasponu prijenosnih brzina od 31 kbit/s do 3081 kbit/s, RMSE vrijednost je 219,925 kbit/s, a PLCC je 0,971. Svi ovi rezultati potvrđuju da predložena metoda koji izračunava točke prebacivanja prostorne rezolucije uzimajući u obzir SITI postiže rezultate usporedive s izmjerenim podacima.



Slika 4.16. Krivulje ovisnosti optimalnih vrijednosti prijenosnih brzina i relativne prostorne rezolucije određene pomoću predložene metode i pomoću izmjerenih podataka.

4.1.3.2. Vrednovanje metode pomoću subjektivne ocjene kvalitete videosignala

Kako bi se potvrdila učinkovitost predložene metode za određivanje optimalnih prijenosnih brzina za promjenu prostornih rezolucija, MC, C47, SK i EM videosignali kodirani su na po dvije prostorne rezolucij, sa svake strane točke prebacivanja prostorne rezolucije (engl. *switching point* - SW) pri istoj kodnoj brzini. Ostvarena prijenosna brzina za videosignale kodirane prema predloženoj metodi bila je jednaka optimalnoj prijenosnoj brzini procijenjenoj prema (4-4). Nakon kodiranja videosignala, provedeno je subjektivno ispitivanje kvalitete 32 kodirana videosignala.

Eksperimentalni dio subjektivnog ispitivanja proveden je s 28 neiskusnih gledatelja u kontroliranom okruženju. Uvjeti gledanja postavljeni su da u što većoj mjeri udovoljavaju onima definiranim u ITU-T [75]. Prije ispitivanja, svim sudionicima ispitani su oštrina vida i raspoznavanje boja. Prije početka ispitivanja, svi su se sudionici upoznati s vrstom ocjenjivanja i rasponom ocjena. Kao postupak ispitivanja korištena je ACR-HR metoda. ACR-HR uključuje izvorne videosignale kao samostojeći poticaj. Nakon uklanjanja skrivene reference, PLCC je izračunat za ocjene svakog gledatelja prema odgovarajućim prosječnim ocjenama svih gledatelja kao kriteriji odbijanja. Uzimajući u obzir da ostvarene vrijednosti PLCC-a nisu bile niže od 0,89, sve prikupljene ocjene korištene su za izračunavanje vrijednosti MOS-a za svaki videosignal. Vrijednosti u tablici 4.8 predstavljaju razliku u vrijednostima MOS-a za svaku točku prebacivanja prostorne rezolucije (videosignal kodiran je na višoj i nižoj prostornoj rezoluciji istom kodnom brzinom). Uzimajući u obzir da je razlika u svim slučajevima oko nule, može se zaključiti da predložena metoda točno procjenjuje točke prebacivanja prostorne rezolucije. Subjektivno ispitivanje kvalitete kodiranih videosignala pokazalo je da model odabira prostorne rezolucije daje dobru procjenu prijenosnih brzina na kojima subjektivna kvaliteta videosignala pri višoj prostornoj rezoluciji postaje jednaka kvaliteti videosignala pri nižoj rezoluciji.

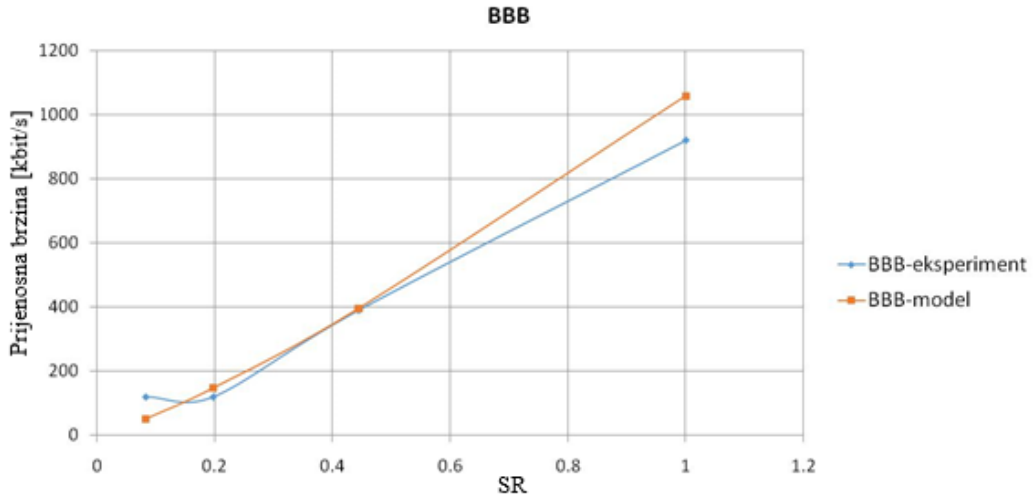
Tablica 4.8. Razlike između vrijednosti MOS-a za dvije prostorne rezolucije u točkama prebacivanja prostorne rezolucije

	Razlika MOS vrijednosti za dvije rezolucije			
Točke prebacivanja	**MC**	**C47**	**SK**	**EM**
SW1 (240p→360p)	0.000	0.000	0.679	0.286
SW2 (360p→480p)	0.071	0.036	0.607	0.000
SW3 (480p→720p)	0.071	0.036	0.036	0.071
SW4 (720p→1080p)	0.071	0.000	0.000	0.286

4.1.3.3. Vrednovanje metode pomoću algoritama za prilagodljivo videostrujanje

Predložena metoda za odabir optimalnih mjesta prebacivanja prostorne rezolucije također je ispitana u eksperimentu videostrujanja. Videosignal BigBuckBunny kodiran je i segmentiran korištenjem predložene metode te je uspoređen s Lederer segmentacijom pomoću dva različita mrežna ispitna zapisa i dva različita algoritma za prilagodljivo strujanje. BBB videosignal ima vrijednost prostorne informacije SI=31,83, a vremenske informacije TI=7,22 i nije korišten u procesu modeliranja. Krivulje iskazane pomoću točaka prebacivanja prostorne rezolucije određene

na temelju izmjerenih podataka i na temelju točaka prebacivanja prostorne rezolucije izračunatim predloženom metodom primjenom (4-4) prikazane su na slici 4.17. Nakon određivanja optimalnih prijenosnih brzina za prebacivanje prostorne rezolucije izračunatim pomoću predložene metode odabrane su prijenosne brzine za skup reprezentacija. Tablica 4.9. prikazuje parametre reprezentacija predložene od strane autora u radu [4] i odgovarajuće parametre reprezentacija odabrane predloženom metodom.



Slika 4.17. Krivulje iskazane pomoću točaka prebacivanja prostorne rezolucije određene pomoću izmjerenih podataka i pomoću predložene metode za BBB videosignal

Da bi se mogle usporediti obje sheme segmentacije, predložena segmentacija koristi iste prostorne rezolucije, isti broj reprezentacija i isti raspon kodnih brzina. Videosignali su segmentirani pomoću programa MP4Box koji kao izlaz daje sve videosegmente, prateću MPD datoteku odabranog profila (*live*) i početni segment za inicijalizaciju dekodera.

Slijedi linija koda korištena za segmentaciju videosignala:

MP4Box -dash 2000 -frag 2000 –rap –dash-profile live -segment-name $RepresentationID$_BigBuckBunny2s_ -out BigBuckBunny_2s.mpd big_buck_bunny_240p24_50_2.mp4

Tablica 4.9. Parametri reprezentacija za Lederer segmentaciju i za predloženu segmentaciju

Lederer segmentacija		Predložena segmentacija	
Prostorna rezolucija	Kodna brzina [kbit/s]	Prostorna rezolucija	Kodna brzina [kbit/s]
320x240	50	320x240	50
320x240	100	**480x360**	**100**
320x240	150	480x360	150
480x360	**200**	**854x480**	**200**
480x360	250	854x480	250
480x360	300	854x480	300
480x360	400	854x480	400
480x360	500	**1280x720**	**500**
854x480	**600**	1280x720	600
854x480	700	1280x720	700
1280x720	**900**	1280x720	900
1280x720	1200	1280x720	1200
1280x720	1500	**1920x1080**	**1500**
1280x720	2000	1920x1080	2000
1920x1080	**2500**	1920x1080	2500
1920x1080	3000	1920x1080	3000
1920x1080	4000	1920x1080	4000
1920x1080	5000	1920x1080	5000
1920x1080	6000	1920x1080	6000
1920x1080	8000	1920x1080	8000

Za potrebe ispitivanja točnosti predložene metode korišteni su algoritmi LIU i SARA. Kao što je ranije opisano, LIU algoritam odluku o reprezentaciji za sljedeći segment donosi na osnovu dostupne propusnosti s tim da pazi da popunjenost međuspremnika ne padne ispod unaprijed definirane vrijednosti. SARA odluku o reprezentaciji za sljedeći segment donosi na osnovu dostupne propusnosti, zauzetosti međuspremnika (raspoznaje tri praga popunjenosti međuspremnika) i veličine segmenta.

Zbog činjenice da SARA koristi MPD datoteke proširene veličinama segmenata, nakon segmentacija videosignala, MPD datoteke i za nove segmente i za segmente iz baze videosignala opisane u [4] dopunjene su informacijama o veličinama segmenata u sljedećem obliku:

<SegmentSize id="1_BigBuckBunny10s_2.m4s" size="496.0" scale="Kbits"/>

U svrhu ispitivanja korištena su dva različita mrežna ispitna zapisa kako bi se simulirali različiti uvjeti u mreži. U prvom ispitnom zapisu, povećanje dostupne propusnosti mijenja se postupno s prosječnom dostupnom propusnosti od 7 Mbit/s. U drugom ispitnom zapisu, iako je povećanje dostupne propusnosti postupno, dolazi do nekoliko naglih smanjenja dostupne propusnosti. U drugom ispitnom zapisu prosječna dostupna propusnost je 4,5 Mbit/s.

Nadalje, u eksperimentu su korištena tri različita trajanja segmenta od 2, 4 i 6 sekundi. Nakon strujanja videosegmenata, preuzeti videosegmenti povezani su u 24 videosignala. Svim prenesenim videosignalima je zatim prostorna rezolucija povećana na prostornu rezoluciju izvornog videosignala odnosno na 1920 x 1080 prostornu rezoluciju te izračunate SSIM vrijednosti. Sve izračunate vrijednosti SSIM-a prikazane su u tablici 4.10.

Može se vidjeti da predložena segmentacija postiže bolje rezultate od Lederer segmentacije u 83,33% slučajeva. Lederer segmentacijom postiže se veći SSIM za strujanje videosignala samo za prvi mrežni ispitni zapis i veličinu segmenta od 10 sekundi.

Tablica 4.10. SSIM vrijednosti videosignale nakon strujanja s primjenom Lederer segmentacije i predložene segmentacije

			Trajanje segmenta [s]		
Lederer segmentacija	**Ispitni mrežni zapis**	**Algoritam**	2	6	10
	1	***SARA***	0,953	0,942	**0,942**
		LIU	0,927	0,933	**0,933**
	2	***SARA***	0,902	0,897	0,913
		LIU	0,908	0,908	0,915
Predložena segmentacija		**Algoritam**	2	6	10
	1	***SARA***	**0,966**	**0,954**	0,935
		LIU	**0,966**	**0,948**	0,927
	2	***SARA***	**0,951**	**0,934**	**0,923**
		LIU	**0,956**	**0,940**	**0,923**

4.2. Metoda za odabir broja i parametara reprezentacija

Prethodno opisana metoda namijenjena je određivanju vrijednosti prijenosnih brzina pri kojima je optimalno prijeći na višu prostornu rezoluciju za pojedini videosignal, no ne daje informaciju o optimalnom broju reprezentacija niti o načinu izbora prijenosnih brzina između onih kod kojih treba promijeniti rezoluciju.

U nastavku istraživanja opisana je metodologija razvoja i zapis metode za odabir broja i parametara reprezentacija koji se mogu koristiti u sustavima temeljenim na MPEG DASH normi. Metoda je zasnovana na mjerenjima indeksa strukturne sličnosti SSIM, MOS-u i prostornim i vremenskim informacijama videosignala. Ideja je pojednostaviti postupak odabira optimalnih skupova reprezentacija uzimajući u obzir kompleksnost videosadržaja i eliminirati potrebu za višestrukim probnim kodiranjem.

4.2.1. Dostupna istraživanja

Kao što je opisano u poglavlju 4.1.1, dostupno je vrlo malo istraživanja koja su usredotočena na parametre kodiranja videosignala, odabir optimalnih parametara za skupove reprezentacija, a posljedično i razvoj baza podataka s videosignalima pripremljenim za istraživanja sustava zasnovanim na MPEG DASH normi.

Jedno od rješenja problema odabira broja reprezentacija opisano je u [72], gdje se parametri za skupove reprezentacija odabiru analizom složenosti kodiranja sadržaja i vrijednosti objektivnih ocjena videosignala određenih pomoću VMAF metode. Raspon mogućih prijenosnih brzina određuje se analizom složenosti kodiranja videosignala, dok je broj reprezentacija određen ujednačenom raspodjelom prijenosnih brzina pomoću VMAF vrijednosti. Iako predložena metoda uzima u obzir složenost kodiranja, ne navodi sve parametre potrebne za reprodukciju rezultata niti daje zapis predstavljene metode.

Rješenje problema odabira broja reprezentacija opisano u [107] odabire parametre skupa reprezentacija pomoću RQ krivulja određenih probnim kodiranjem (vrši se kodiranje u više prolaza i mjeri se prijenosna brzina svakog segmenta) i izračunavanjem PSNR vrijednosti. Broj reprezentacija odabire se pomoću parametra najmanje uočljive razlike (engl. *Just Noticeable Difference* - JDN) tako da susjedne reprezentacije budu na udaljenosti od jednog JDN i da prirast kodnih brzina iznosi oko 5%. Zbog probnog kodiranja, predloženo rješenje koristi veliku količinu računalne snage. U ostaloj dostupnoj literaturi, istraživanja koja rješavaju problem odabira

parametara reprezentacija, nema dostupnih informacija o tome kako je odabran broj reprezentacija [6, 103].

Kao što se može vidjeti iz pregleda dostupnih istraživanja, većina prethodno spomenutih rješenja za odabir optimalnih parametara za skupove reprezentacija koristi puno računalnih resursa zbog probnog kodiranja ili ne iskazuju sve parametre potrebne za reprodukciju rezultata. Također, u dijelu istraživanja se ne uzima u obzir složenost sadržaja videosignala.

4.2.2. Razvoj metode za odabir broja i parametara reprezentacija

Razvoj metode za odabir broja i parametara reprezentacija započeo je određivanjem točaka koje opisuju anvelopu krivulja ovisnosti SSIM-a o prijenosnoj brzini za 10 videosignala: *Chimera1102353* (C53), *Meridian Conversatio*n (MC), *Chimera1102347* (C47), *Station2* (S2), *Pedestrian Area* (PA), *Skateboarding* (SK), *Tears Of Steel Robot* (T53) (EM), *Grand Theft Auto* (GTA), *Soccer* (SO) i *Blue Sky* (BS). Videosignali su kodirani na 5 prostornih rezolucija: 240p, 360p, 480p, 720p i 1080p. Točke anvelope određene su za svaki pojedini videosignal kao najveće SSIM vrijednost za promatranu prijenosnu brzinu neovisno o prostornoj rezoluciji, odnosno kao anvelopa svih 5 krivulja ovisnosti SSIM o prijenosnoj brzini za 5 prostornih rezolucija. Tako očitane točke korištene su za određivanje funkcijske ovisnosti *SSIManv* o prijenosnoj brzini (*PB*). Primjer točaka anvelope određenih za videosignal MC čije su krivulje ovisnosti SSIM-a o prijenosnoj brzini prikazane slikom 4.3. prikazan je slikom 4.18.

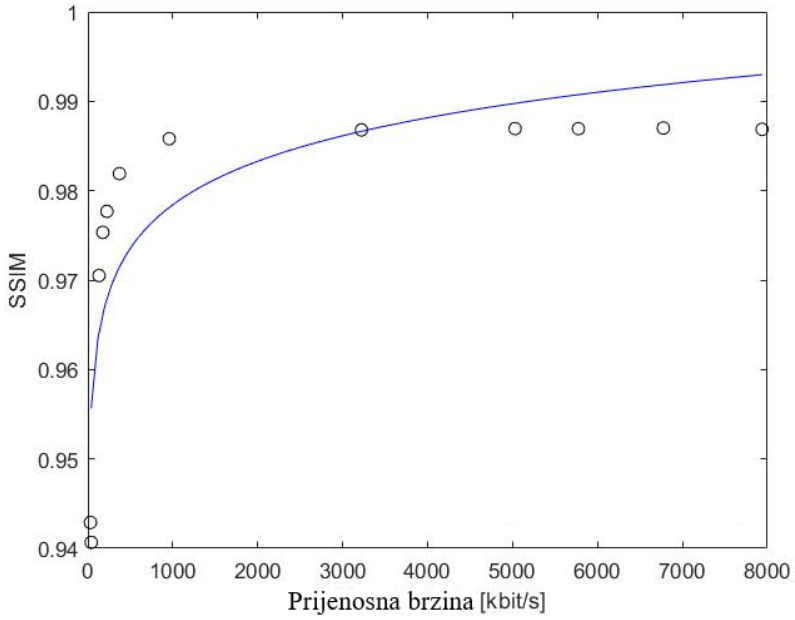
Na temelju tako dobivenih krivulja *SSIManv* - *PB*, odabrana je nelinearna logaritamska funkcija (4-5) za teorijski model ovisnosti *SSIManv* o *PB*.

$$SSIManv(PB) = A \cdot ln(PB) + B \tag{4-5}$$

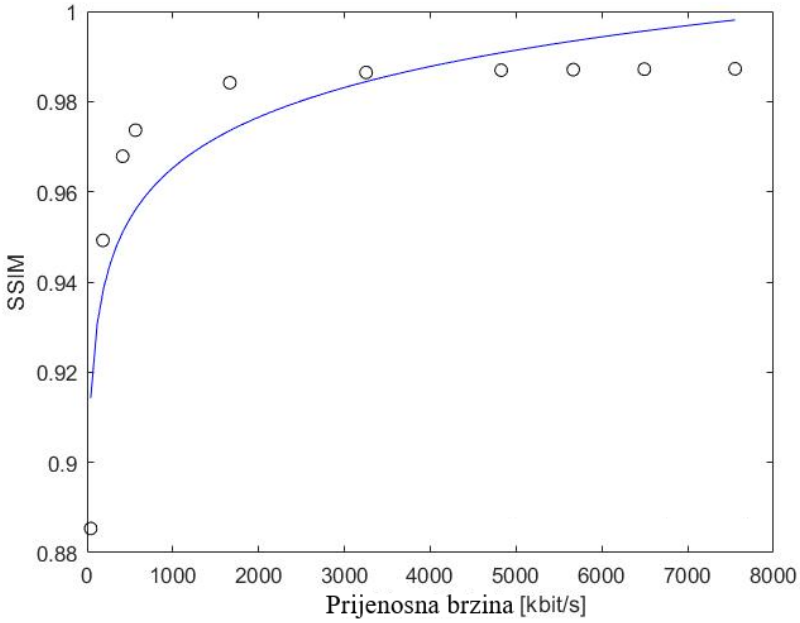
Koeficijenti A i B u (4-5) određeni su za svaki videosignal korištenjem funkcije *lscurvefit* u Matlabu. Točke koje opisuju anvelopu krivulja ovisnosti SSIM-a o prijenosnoj brzini i pripadajuće krivulje opisane izrazom (4-5) za videosignale C47, MC, SK i EM prikazane su na slikama 4.18 do 4.21. Slike 4.18 do 4.21 pokazuju da se krivulje opisane izrazom (4-5) mogu koristiti za procjenu vrijednosti *SSIManv* pomoću vrijednosti prijenosne brzine PB za određeni videosignal.

Vrijednosti koeficijenata A i B, kao i PLCC vrijednosti izračunate za svaki videosignal korišten u procesu modeliranja prikazani su u tablici 4.11. PLCC vrijednosti izračunate su kako bi se iskazala korelacija između izmjerenih vrijednosti anvelope SSIM-a i modeliranih vrijednosti

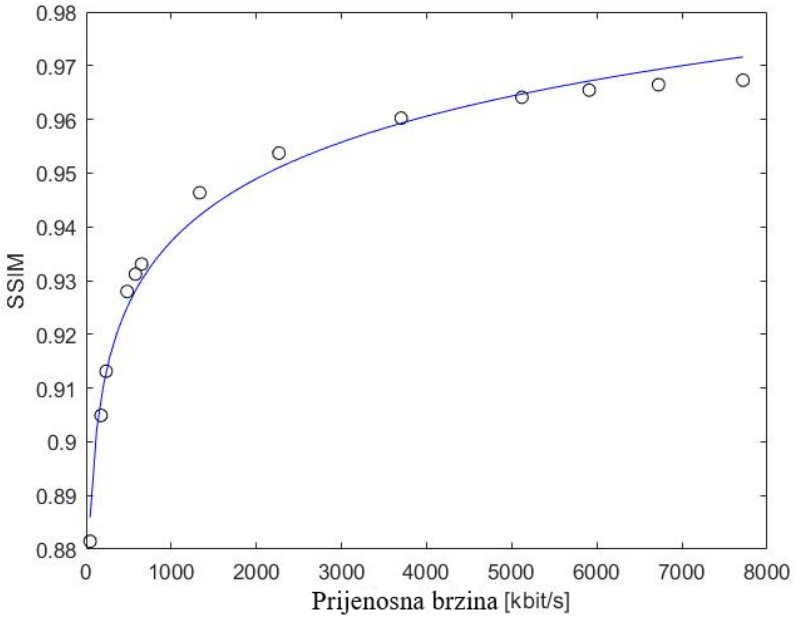
SSIManv. Srednja vrijednost PLCC-a za sve videosignale je 0,953, što ukazuje da se predloženim modelom se postižu rezultati koji dobro odgovaraju izmjerenim vrijednostima.



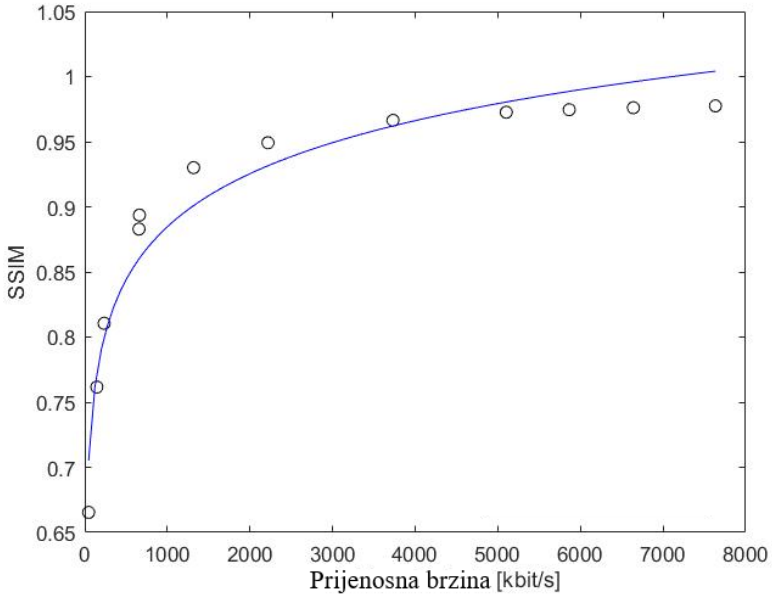
Slika 4.18. Točke koje opisuju anvelopu krivulje ovisnosti SSIM-a o prijenosnoj brzini i pripadajuće krivulje opisane izrazom (4-5) za videosignal *Meridian Conversatio*n (MC)



Slika 4.19. Točke koje opisuju anvelopu krivulje ovisnosti SSIM-a o prijenosnoj brzini i pripadajuće krivulje opisane izrazom (4-5) za videosignal Chimera1102347 (C47)



Slika 4.20. Točke koje opisuju anvelopu krivulje ovisnosti SSIM-a o prijenosnoj brzini i pripadajuće krivulje opisane izrazom (4-5) za videosignal Skateboarding (SK)



Slika 4.21. Točke koje opisuju anvelopu krivulje ovisnosti SSIM-a o prijenosnoj brzini i pripadajuće krivulje opisane izrazom (4-5) za videosignal ElFuenteMask (EM)

Tablica 4.11. Vrijednosti koeficijenata *A* i *B*, kao i PLCC vrijednosti izračunate za videosignale korištene u procesu modeliranja. PLCC vrijednosti predstavljaju korelaciju između krivulja opisane izrazom (4-5) i izmjerenih vrijednosti.

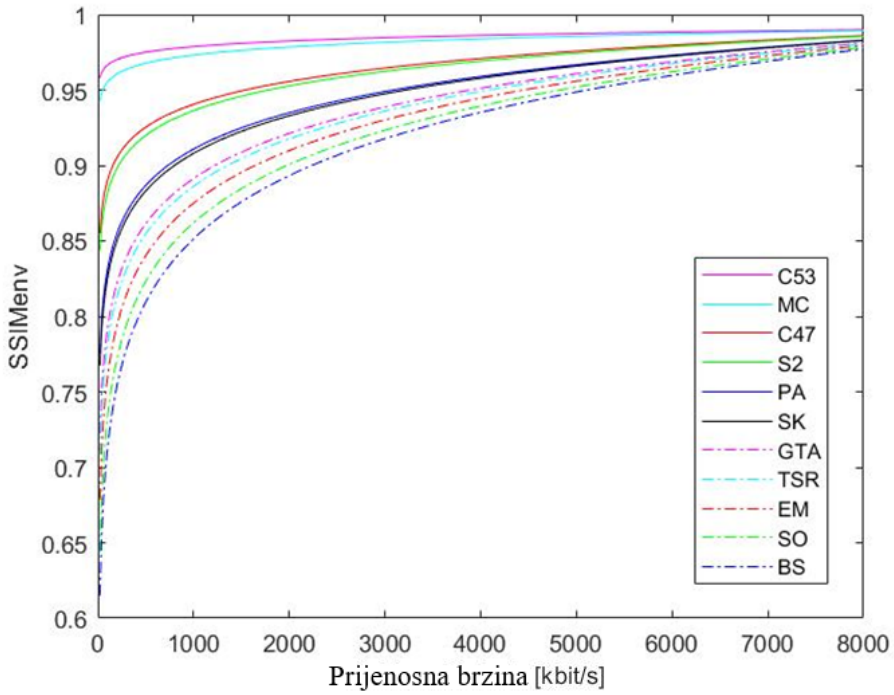
Naziv videosignala	**A**	**B**	**PLCC**
C53	0.0043	0.939	0.9095
MC	0.007	0.9299	0.859
C47	0.0162	0.8533	0.8903
S2	0.0428	0.6141	0.9515
PA	0.0402	0.6359	0.9748
SK	0.0168	0.8213	0.9937
GTA	0.0419	0.5239	0.9955
TSR	0.0394	0.6234	0.9943
EM	0.0588	0.4789	0.9732
SO	0.0741	0.3265	0.994
BS	0.0565	0.5014	0.9496

Slika 4.22. prikazuje krivulje ovisnosti *SSIManv* o prijenosnim brzinama za sve videosignale korištene u procesu modeliranja. Vidljivo je da su vrijednosti *SSIManv* niže za videosignale s većom vrijednosti parametra SITI za zadane prijenosne brzine, jer je videosignale s višom razinom prostorne i vremenske aktivnosti teže kodirati, a za određenu razinu kvalitete stupanj kompresije je niži nego što je kod videosignala manje složenosti.

Postavlja se pitanje može li se promatrano ponašanje izraziti kao funkcijska ovisnost između *SSIManv(PB)* i SITI. Istraživanjem je utvrđeno da se odnos između parametra *A* i *SITI,* kao i *B* i *SITI* može također izraziti logaritamskom funkcijom *f(SITI),* (4-6).

$$f(SITI) = X \cdot ln(SITI) + Y \tag{4-6}$$

Jednadžba (4-6) koristi se za opisivanje ovisnosti *A(SITI)* i za *B(SITI)*, ali s različitim parametrima, *X* i *Y*. SITI se pokazao kao odgovarajuća mjera koja se može koristiti za opisivanje prostorne i vremenske aktivnosti videosignala, a time i njihove složenosti kodiranja. Koeficijenti *X* i *Y* određeni su pomoću funkcije *lscurvefit* u Matlabu te su zajedno sa PLCC vrijednostima prikazani u tablici 4.12.

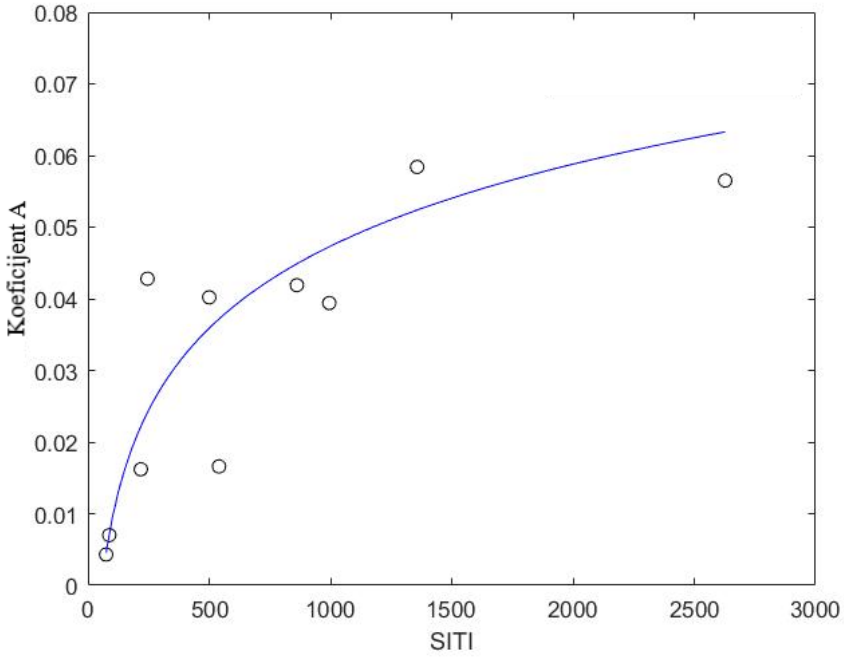


Slika 4.22. Krivulja ovisnosti *SSIManv* o prijenosnim brzinama za sve videosignale korištene u procesu modeliranja

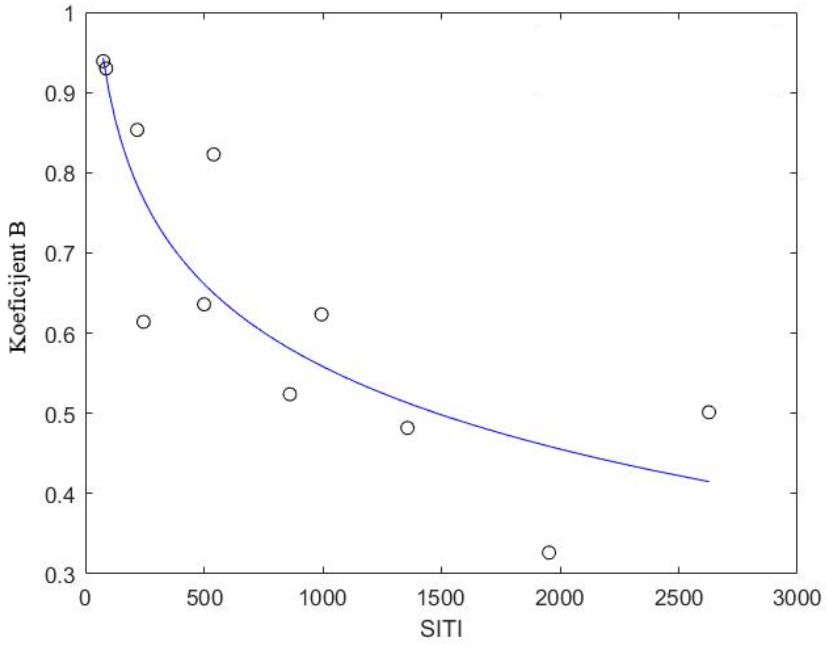
Slike 4.23. i 4.24. prikazuju krivulje određene pomoću izraza (4-6) koji opisuje funkcijske ovisnosti *A(SITI)* i *B(SITI)*. Kao što se može vidjeti na slikama 4.23. i 4.24., kao i iz PLCC vrijednosti, dobivene krivulje određene pomoću izraza (4-6) točno opisuju funkcijsku ovisnost između koeficijenata *A, B* i SITI-ja.

Tablica 4.12. Vrijednosti *X* i *Y* koeficijenata koji su rezultat određivanja ovisnosti *A* i *B* o SITI-ju. PLCC vrijednosti predstavljaju korelaciju između modeliranih i izmjerenih vrijednosti

	X	**Y**	**PLCC**
A	0.0165	-0.0668	0.8715
B	-0.1485	15.843	0.8789



Slika 4.23. Točke koje opisuju ovisnost koeficijenta *A* o SITI-ju i pripadajuća krivulja opisana izrazom (4-6)



Slika 4.24. Točke koje opisuju ovisnost koeficijenta *A* o SITI-ju i pripadajuća krivulja opisana izrazom (4-6)

Korištenjem (4-5) i (4-6), funkcijska ovisnost *SSIManv* o prijenosnoj brzini i umnošku prostorne i vremenske informacije videosignala može se prikazati izrazom (4-7):

$$SSIM_{anv}(PB, SITI) = (0.0165 \cdot ln(SITI) - 0.0668) \cdot ln(PB) + (-0.1485 \cdot ln(SITI) + 1.5843) \quad (4\text{-}7)$$

U izrazu (4-7) prijenosna brzina PB je iskazana u kbit/s. Predložena metoda može se koristiti za procjenu SSIM vrijednosti za videosignal koji je kodiran određenom prijenosnom brzinom PB samo ako je poznata SITI vrijednost za taj videosignal. Treba naglasiti da za ispravnu primjenu ove metode potrebno je odabrati optimalnu prostornu rezoluciju za određenu prijenosnu brzinu PB i SITI prema metodi opisanoj u poglavlju 4.1.

Preciznost metode analizirana je usporedbom SSIManv vrijednosti izračunate s (4-7) i izmjerenih SSIM vrijednosti za svaki kodirani videosignal. Usporedba vrijednosti SSIM i SSIManv izvršena je pomoću videosignala kodiranih na 32 različite prijenosne brzine u rasponu od 50 kbit/s do 8 Mbit/s. Rezultati za četrnaest videosignala koji su korišteni za modeliranje, kao i za tri videosignala koji nisu korištena u procesu modeliranja prikazani su u tablici 4.13.

Može se vidjeti da je srednja razlika između izmjerenih vrijednosti SSIM i SSIManv vrijednosti određenih predloženom metodom 4,28% za skupinu videosignala korištenih u procesu modeliranja ((C53, MC, C47, S2, PA, SK, GTA, TSR, EM SO i BS) i 5,84% za skupinu videosignala koji nisu korišteni u procesu modeliranja (BBB, ED i TR). Vrijednosti PLCC-a veće su od 0,91 za obje skupine videosignala.

Tablica 4.13. Usporedba izmjerenih vrijednosti SSIM i SSIManv za videosignale koji su korišteni u procesu modeliranja (C53, MC, C47, S2, PA, SK, GTA, TSR, EM SO i BS), i videosignala koji nisu korišteni u procesu modeliranja (BBB, ED i TR).

Videosignali korišteni u modeliranju		**Ispitni videosignali**	
Srednja vrijednost (SSIM-SSIManv)	0,0343	Srednja vrijednost (SSIM-SSIManv)	0,0448
Srednja vrijednost (SSIM-SSIManv) [%]	4,2832	Srednja vrijednost (SSIM-SSIManv) [%]	5,8393
RMSE	0,0428	RMSE	0,0594
PLCC	0,9188	PLCC	0,9377

4.2.3. Optimalni skup reprezentacija

Metoda iskazana izrazom (4-7) može se koristiti za određivanje optimalnog skupa reprezentacija definiranjem vrijednosti SSIManv koje se žele dobiti za pojedinu reprezentaciju. Međutim, s obzirom da SSIM i MOS prema [7] imaju nelinearnu međusobnu vezu, bolji način za odabir optimalnih reprezentacija je definiranjem vrijednosti MOS-a koje se žele dobti za pojedinu reprezentaciju. To je moguće napraviti pomoću preslikavanja SSIManv vrijednosti na ljestvicu 0-100 MOS vrijednosti pomoću jednadžbe (4-8), [7].

$$MOS^p = 228.417 - 919.711 \cdot SSIM_{env} + 1193.227 \cdot {SSIM_{env}}^2 - 405.344 \cdot {SSIM_{env}}^3 \quad (4\text{-}8)$$

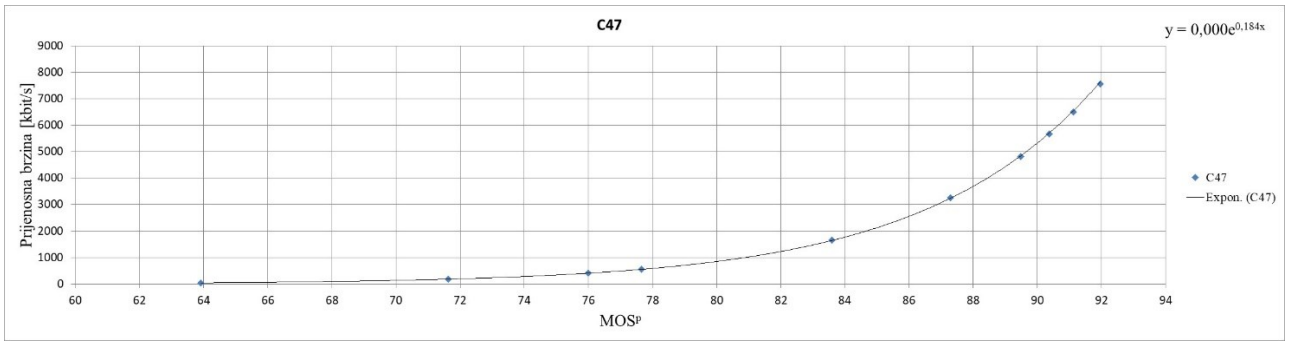
gdje MOS^p predstavlja procjenu kvalitete koju percipira korisnik videosignala ocijenjenog sa *SSIMenv* vrijednosti, [7]. Treba napomenuti da se korištenjem (4-7) i (4-8) također može iskazati ovisnost MOS^p o prijenosnoj brzini i SITI-ju.

Da bi se odredile prijenosne brzine na koje se videosignal treba kodirati kako bi se dobio dobro uravnotežen skup reprezentacija, potrebno je napraviti još jedan korak. Korištenjem (4-7) i (4-8) prijenosna brzina izražena u ovisnosti o vrijednosti MOS^p za zadani SITI opisana je izrazom (4-9) i krivuljama prikazanim na slikama 4.25 do 4.28.

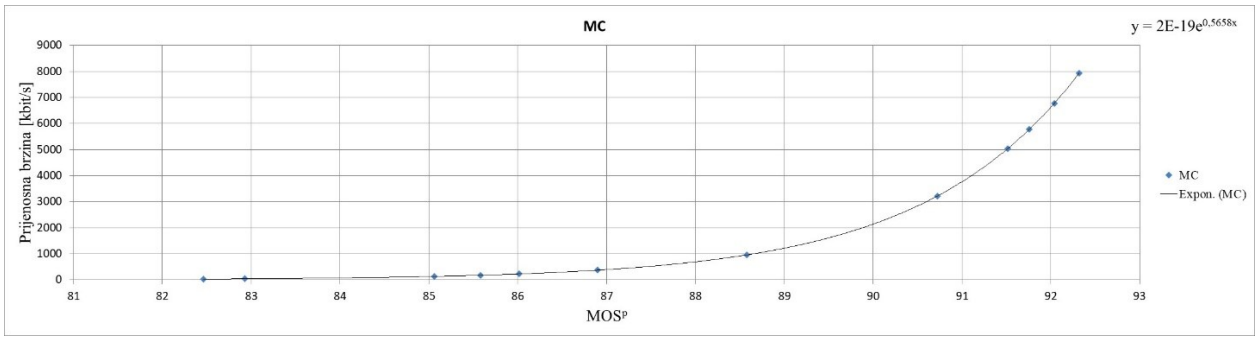
$$BR = C1 \cdot exp(C2 \cdot MOS^p) \quad (4\text{-}9)$$

Koeficijenti *C1* i *C2* izračunati za svaki videosignal prikazani su u tablici 4.14. Srednja vrijednost PLCC za sve videosignale korištene u procesu modeliranja iznosi 0,997.

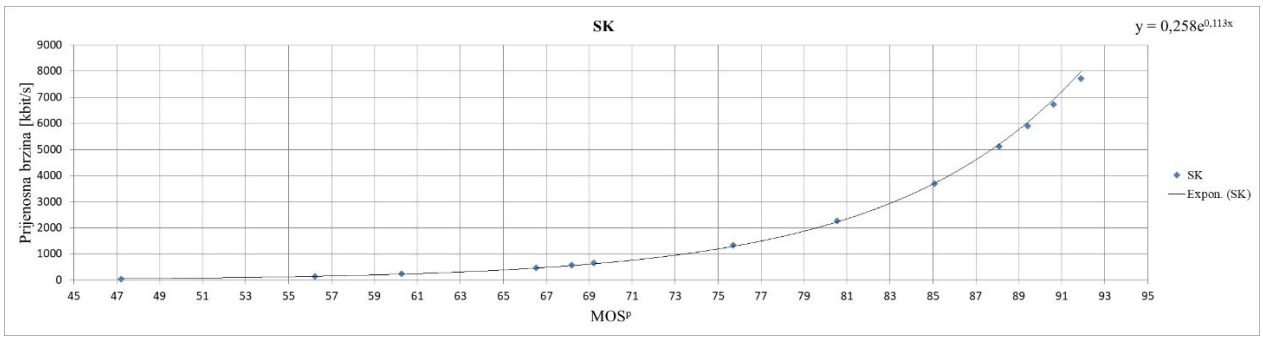
Pomoću funkcije (4-9) moguće je odrediti optimalne vrijednosti prijenosnih brzina za skupove reprezentacija za svaki videosignal na temelju vrijednosti SITI i MOS^p. Dobro uravnoteženi skupovi reprezentacija ne bi trebali imati ni previše ni premalo razina kvalitete (tj. prijenosnih brzina) kako bi se korisniku prilikom strujanja videosignala pružila optimalna prilagodljivost.



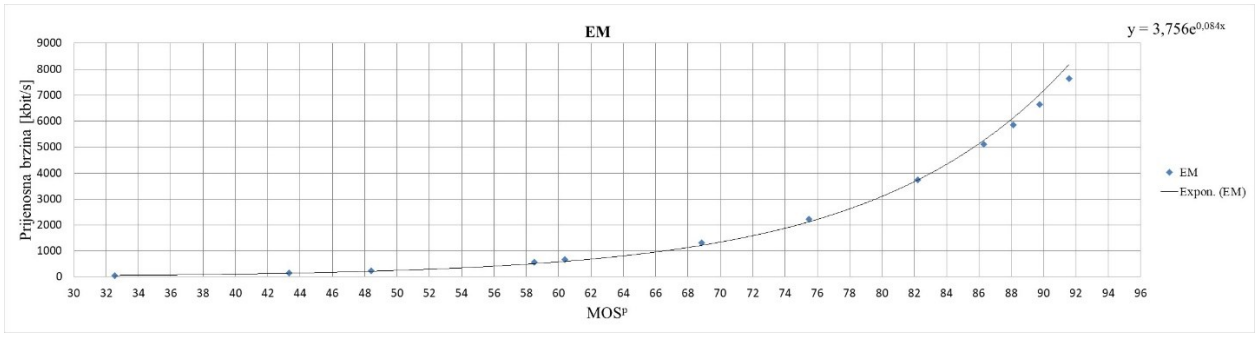
Slika 4.25. Krivulja ovisnosti prijenosne brzine o vrijednosti MOS^p *Chimera1102347* (C47)



Slika 4.26. Krivulja ovisnosti prijenosne brzine o vrijednosti MOS^p *Meridian Conversation* (MC).



Slika 4.27. Krivulja ovisnosti prijenosne brzine o vrijednosti MOS^p *Skateboarding* (SK)



Slika 4.28. Krivulja ovisnosti prijenosne brzine o vrijednosti MOS^p *El Fuente Mask* (EM)

Tablica 4.14. Vrijednosti koeficijenata *C1* i *C2* koje se koriste za opis funkcijske ovisnosti prijenosne brzine o vrijednosti MOS^p za svaki videosignal korišten u procesu modeliranja, kao i za BBB

	C1	**C2**
C53	1E-32	0.8946
MC	2E-19	0.5658
C47	0.00036	0.1835
S2	0.0014	0.1691
PA	0.1818	0.1163
SK	0.2579	0.1125
GTA	1.7773	0.0887
TSR	1.8674	0.0913
EM	3.7564	0.0839
SO	7.1434	0.0772
BS	10.7114	0.0731
BBB	0.00067	0.1768

Nadalje, logično je da prijenosne brzine za videosignal budu odabrane tako da promjena predviđene subjektivne kvalitete (ΔMOS^p) s razine na razinu bude konstantna. Uzimajući u obzir navedene pretpostavke te krivulje ovisnosti prijenosne brzine o MOS^p vrijednostima prikazanih na slici 4.24, može se zaključiti da će broj razina kvalitete za videosignale s nižim SITI-jem biti manji nego za videosignale s višim SITI-jem. Iz toga slijedi da bi se dobio dovoljan broj razina kvalitete za videosignale s nižim SITI-jem, za njih bi ΔMOS^p trebao bi biti niži.

Daljnjim istraživanjem je utvrđeno da je za određivanje parametara skupa reprezentacija preporučljivo odabrati prijenosne brzine za videosignale sa SITI-jem nižim od 100 pomoću ΔMOS^p= 1, za videoignale sa SITI-jem većim od 100 i nižim od 500 pomoću ΔMOS^p= 2, a za videoignale sa SITI-jem većim od 500 pomoću ΔMOS^p = 3.

Nadalje, za videosignale s prostornom rezolucijom 1080p i kodiranje H.264 kodekom nije preporučljivo koristiti prijenosne brzine koje odgovaraju MOS^p vrijednostima nižim od 40 i koristiti kodnu brzinu manju od 50 kbit/s. Uz ove preporuke, korištenjem navedenih koraka ΔMOS^p između pojedinih reprezentacija, dobit će se optimalan broj reprezentacija, u rasponu od 7 do 19.

4.3. Vrednovanje metode za odabir optimalnih razina kvalitete u postupku kodiranja i segmentacije videosignala za prilagodljivo videostrujanje

Ispitivanje točnosti predložene metode za odabir broja i parametara reprezentacija provedeno je primjenom algoritama za prilagodljivo videostrujanje te analizom subjektivnih ocjena kvalitete videosignala dobivenih uz pomoć 26 neiskusnih gledatelja u kontroliranom okruženju.

4.3.1. Vrednovanje metode pomoću algoritama za prilagodljivo videostrujanje

Predložena metoda za određivanje optimalnog broja skupova reprezentacija koja uzima u obzir vrijednosti prostorne i vremenske informacije videosignala ispitana je pomoću BigBuckBunny videosignala koji nije korišten u procesu modeliranja. BBB je segmentiran u 16 reprezentacija gdje su prijenosne brzine odabrane pomoću predloženog modela, dok su prostorne rezolucije određene pomoću pripadajućeg modela opisanog u poglavlju 4.1. Prostorne rezolucije i prijenosne brzine korištene u ovom ispitivanju, kao i vrijednosti MOS^p korištene za određivanje reprezentacija za predloženu segmentaciju, navedene su u tablici 4.15. Također, za potrebe ispitivanja, BBB je segmentiran korištenjem trajanja segmenata od 2, 6 i 10 sekundi. Predložena segmentacija ispitana je pomoću dva različita mrežna ispitna zapisa i dva algoritma za prilagodljivo videostrujanje, LIU i SARA.

U prvom mrežnom ispitnom zapisu, raspoloživa mrežna propusnost imala je srednju vrijednost 7 Mbit/s, dok je u drugom mrežnom ispitnom zapisu raspoloživa mrežna propusnost imala srednju vrijednost od 4 Mbit/s. U usporedbi s prvim mrežnim ispitnim zapisom gdje su promjene u raspoloživoj propusnosti bile postupne, drugi je mrežni ispitni zapis imao nagle promjene u raspoloživoj propusnosti.

Za strujanje segmentiranih videosignala korišten je sustav A-Stream [111] razvijen pomoću programskog jezika Python. Nakon strujanja, primljeni videosegmenti spojeni su u videosignale koji su skalirane na izvornu prostornu rezoluciju od 1080p kako bi se izračunale SSIM vrijednosti. Izračunate vrijednosti SSIM navedene su u tablici 4.16. Na temelju SSIM vrijednosti može se zaključiti da predložena segmentacija ostvaruje veće vrijednosti SSIM-a u odnosu na Lederer segmentaciju u 92% slučajeva. Stoga, predložena segmentacija predstavlja poboljšanje prethodno dostupne segmentacija, isključuje potrebu za probnim kodiranjem, a istovremeno se radi o segmentaciji koja optimalni skup reprezentacija odabire uzimajući u obzir prostornu i vremensku aktivnost videosignala. Treba napomenuti da je poboljšanje postignuto s manjim brojem

reprezentacija, što znači da je potrebno i manje memorije na poslužitelju za pohranjivanje videosegmenata.

Tablica 4.15. Parametri za skup reprezentacija za BBB videosignal za Lederer segmentaciju i za predloženu segmentaciju.

Lederer segmentacija		**Predložena segmentacija**		
Prostorna rezolucija	**Kodna brzina [kbit/s]**	**Prostorna rezolucija**	**Kodna brzina [kbit/s]**	$\boldsymbol{MOS^p}$
320x240	50	320x240	50	63
320x240	100	480x360	70	65
320x240	150	480x360	100	67
480x360	200	480x360	150	69
480x360	250	854x480	250	71
480x360	300	854x480	350	73
480x360	400	854x480	500	75
480x360	500	1280x720	700	77
854x480	600	1280x720	950	79
854x480	700	1920x1080	1500	81
1280x720	900	1920x1080	2000	83
1280x720	1200	1920x1080	3000	85
1280x720	1500	1920x1080	4000	87
1280x720	2000	1920x1080	5500	89
1920x1080	2500	1920x1080	7500	91
1920x1080	3000	1920x1080	10500	93
1920x1080	4000			
1920x1080	5000			
1920x1080	6000			
1920x1080	8000			

Tablica 4.16. SSIM vrijednosti određene za videosignal BBB segmentiran korištenjem Lederer segmentacije i predložene segmentacije

			Trajanje segmenta [s]		
		Algoritam	**2**	**6**	**10**
Lederer segmentacija	**Ispitni zapis 1**	**SARA**	0.953	0.942	0.942
		LIU	0.927	0.933	0.933
	Ispitni zapis 2	**SARA**	0.902	0.897	0.913
		LIU	0.908	0.908	0.915
Predložena segmentacija	**Ispitni zapis 1**	**SARA**	**0.962**	**0.948**	0.937
		LIU	**0.965**	**0.950**	**0.937**
	Ispitni zapis 2	**SARA**	**0.934**	**0.935**	**0.929**
		LIU	**0.953**	**0.943**	**0.929**

4.3.2. Ocjena rezultata pomoću subjektivne metode za ocjenu kvalitete videosignala

Kako bi se potvrdila točnost predloženog modela, kodirani videosignali za Lederer segmentaciju i predloženu segmentaciju ocjenjeni su pomoću subjektivne metode za ocjenu kvalitete videosignala. Subjektivno ispitivanje je provedeno za 24 kodirana videosignala nakon videostrujanja i izvornog videosignala. Eksperimentalni dio subjektivnog ispitivanja proveden je s 32 neiskusna gledatelja u kontroliranom okruženju u skladu s preporukama ITU-T [75]. Prije ispitivanja, svim sudionicima ispitani su oštrina vida i raspoznavanje boja te su svi sudionici upoznati s vrstom ocjenjivanja i rasponom ocjena. Kao postupak ispitivanja korištena je ACR-HR metoda. Nakon uklanjanja skrivene reference, PLCC je izračunat za ocjene svakog gledatelja prema odgovarajućim prosječnim ocjenama svih gledatelja kao kriteriji odbijanja.

S obzirom da su ostvarene vrijednosti PLCC-a za šest gledatelja bile manje od 0,75, prikupljene ocjene 26 gledatelja korištene su za izračunavanje vrijednosti MOS-a za svaki videosignal (tablica 4.17.). Vrijednosti u tablici 4.18. predstavljaju razliku u vrijednostima MOS-a za Lederer segmentaciju i predloženu segmentaciju. Kao što je vidljivo iz tablica 4.17. i 4.18, subjektivno ispitivanje kvalitete kodiranih videosignala pokazalo je da predložena metoda odabira broja i parametara reprezentacija ostvaruje bolje rezultate u odnosu na Lederer segmentaciju u 83,3% slučajeva. Pri tome je za predloženu segmentaciju ostvarena MOS vrijednost veća za 0,263 u odnosu na MOS vrijednosti za Lederer segmentaciju.

Tablica 4.17. Ostvarene vrijednosti MOS-a za Lederer segmentaciju i predloženu segmentaciju

			Trajanje segmenta [s]		
		Algoritam	2	6	10
Lederer segmentacija	**Ispitni zapis 1**	***SARA***	4,46	3,38	3,35
		LIU	4,27	3,15	3,31
	Ispitni zapis 2	***SARA***	3,12	3,08	3,42
		LIU	3,69	3,12	3,54
Predložena segmentacija		**Algoritam**	2	6	10
	Ispitni zapis 1	***SARA***	**4,77**	**3,77**	3,15
		LIU	**4,62**	**3,54**	**3,46**
	Ispitni zapis 2	***SARA***	**4,00**	**3,42**	3,27
		LIU	**4,31**	**3,46**	**3,62**

Tablica 4.18. Razlika vrijednosti MOS-a za Lederer segmentaciju i predloženu segmentaciju

		Trajanje segmenta [s]		
	Algoritam	2	6	10
Ispitni zapis 1	***SARA***	0,31	0,38	-0,19
	LIU	0,35	0,38	0,15
Ispitni zapis 2	***SARA***	0,88	0,35	-0,15
	LIU	0,62	0,35	0,08

5. BAZA KODIRANIH I SEGMENTIRANIH VIDEOSIGNALA SA SKUPOM PARAMETARA ZA PRILAGODLJIVO VIDEOSTRUJANJE ZASNOVANO NA MPEG DASH NORMI

Istraživanjem parametara kvalitete korisničkog iskustva u videostrujanju, algoritama za prilagodljivo strujanje i metoda koje se mogu koristiti za određivanje parametara za kodiranje segmentaciju videosignala pojavio se problem nedovoljnog broja videosignala pripremljenih za korištenje u sustavima zasnovanim na MPEG DASH normi. Iako se algoritmi za prilagodljivo videostrujanje razvijaju i unapređuju od nastanka same norme, ne postoji mnogo istraživanja vezanih uz proces segmentacije i baze videosignala sa segmentiranim videosignalima.

5.1. Analiza dostupnih baza za ispitivanje sustava za prilagodljivo videostrujanje

Da bi se naglasila potreba za sveobuhvatnom bazom videosignala sa segmentiranim videosignalima prilagođenim korištenju u sustavima zasnovanim na MPEG DASH normi, sve postojeće baze videosignala opisane u dostupnoj literaturi uspoređene su u tablici 5.1.

Prva ikada objavljena baza videosignala segmentiranih za MPEG DASH normu opisana je u [4]. Baza uključuje pet različitih videosignala dovoljno dugih za ispitivanje sustava zasnovanih na MPEG DASH normi. Uz videosignala, opisano istraživanje uključuje i program DASHEncoder. DASHEncoder je alat za kodiranje i segmentaciju videosignala prema MPEG DASH normi. Predložena baza je rezultat istraživanja utjecaja postavki HTTP poslužitelja i problema koji se javljaju pri korištenju segmenta s kraćim trajanjem. Cilj istraživanja opisanog u [4] bio je odrediti optimalnu prijenosnu brzinu za određenu prostornu rezoluciju. U okviru istraživanja je provedena analiza različitih parova prijenosne brzine i prostorne rezolucije u ovisnosti o PSNR vrijednosti kodiranog sadržaja. PSNR vrijednost svakog kodiranog videosignala izračunata je u odnosu na izvorni videosignal. Kontinuirano povećanje kvalitete videosignala osigurano je pravilnim odabirom prijenosnih brzina za određene prostorne rezolucije. S obzirom na činjenicu da je trajanje segmenata vrlo važno u prilagodljivom strujanju, predložena baza videosignala uključuje videosignale kodirane s trajanjem segmenata od 1, 2, 4, 6, 10 i 15 sekundi. Baza opisana u [4] uključuje videosignale u trajanju od 10 do 90 minuta gdje su videosignali kodirani pomoću jednog od tri predložena skupa reprezentacija s prijenosnim brzinama u rasponu od 50 kbit/s do nekoliko Mbit/s.

Iako je ova baza videosignala pripremljena prema MPEG DASH normi i uključuje videosignale sa šest različitih trajanja segmenta, popratne MPD datoteke dostupne su samo u *onDemand* i *simple* profilu. Također, dva videosignala nemaju uz segmente dostupan in početni segment potreban za inicijalizaciju dekodera.

S obzirom da bi svaka baza videosignala trebala uzimati u obzir utjecaj različitih duljina segmenata na QoE korisnika, potrebno je uzeti u obzir dva zaključka iz [4]:

- Korištenjem segmenata s kraćim trajanjem povećava se broj HTTP zahtjeva i broj prebacivanja između različitih reprezentacija;
- Segmenti s duljim trajanjem se ne bi trebali koristiti u okruženjima s čestim i velikim promjenama u dostupnoj propusnosti jer se smanjuje učinkovitost korisničke aplikacije.

DASH / SVC (engl. *Scalable Video Encoding* - SVC) je baza videosignala koja uključuje četiri podskupa prijenosnih brzina (engl. *bitrate variant*) te je uz bazu dostupan i program za pretvaranje videosignala kodiranih SVC-om u videosignale koji se mogu koristiti u sustavima zasnovanim na MPEG DASH normi [8]. Baza uključuje ukupno dvanaest videosignala, ali osam videosignala ima trajanje samo oko 20 sekundi. Svi videosignali kodirani su vremenskim rezolucijama od 6, 12 i 24 slika po sekundi, a trajanjem segmenta od dvije sekunde i s do četiri sloja za poboljšanje (engl. *enhancement layer*). Prilikom odabira parametara kodiranja uzeta je u obzir činjenica da bi upotreba previše slojeva poboljšanja imala negativan utjecaj na korisničko iskustvo i potencijalno na poslužitelja. Ispitivanjem je utvrđeno da se korištenjem više slojeva za poboljšanje povećava broj HTTP zahtjeva za svaki segment. Uz videosegmente dostupne su i MPD datoteke s *main* profilom te izvorni videosignali [67].

DASH baza videosignala kodiranih s više različitih kodeka [16] uključuje deset videosignala, ali sedam videosignala ima trajanje od samo 20 sekundi, što može biti ograničavajući faktor prilikom određivanja mrežnih ispitnih zapisa za ispitivanje sustava za prilagodljivo videostrujanje. Svi videosignali kodirani su pomoću četiri različita kodeka (AVC, HEVC, VP9 i AV1) s trajanjem segmenta od dvije i četiri sekunde. Uz videosegmente dostupne su i MPD datoteke s *full* profilom. Videosignali u predloženoj bazi segmentirani su na temelju preporuka pružatelja usluga strujanja videosignala i prethodno dostupnih baza videosignala, ali nisu navedene ostale informacije vezane uz odabir skupova reprezentacija [16]. U slučaju kada se koriste skupovi reprezentacija prema preporuci pružatelja usluga strujanja videosignala treba uzeti u obzir da postoje istraživanja koja tvrde da neke preporuke pružatelja usluga strujanja videosignala ne uzimaju u obzir parametre korisničkih uređaja [24].

Distribuirana DASH baza videosignala [24] predstavlja poboljšanje u usporedbi s ostalim dostupnim bazama jer za svaki segment uključuje više poveznica za preuzimanje segmenta (engl. *BaseURL*). Može se koristiti u MPEG DASH sustavima koji imaju mogućnost prikupljanja segmenata s nekoliko povezanih poslužitelja. Predložena baza se sastoji od videosegmenata za samo jedan videosignal i MPD datoteka s *main* i *live* profilima [24].

Iako su baze videosignala opisane i analizirane u [112] i [113], samo je jedan videosignal dostupan za ispitivanje (drugi nisu dostupni zbog autorskih prava) te oba istraživanja ne pružaju informacije o odabiru reprezentacija. Ostale dostupne baze videosignala poput [72, 104] se sastoje od izvornih videosignala, ali ne uključuju videosignale segmentirane za MPEG DASH, samim time ne sadrže ni početne videosegmente ni odgovarajuće MPD datoteke. Obje se baze mogu koristiti za prilagodljivo strujanje, ali je potrebno segmentirati videosignale i MPD datoteke nadopuniti svim potrebnim informacijama. Osim [4] koji navodi da se reprezentacije odabiru analizom PSNR vrijednosti kodiranih videosignala, niti jedna od dostupnih baza videosignala ne sadrži informacije o odabiru reprezentacija.

Iz analize dostupnih baza videosignala i tablice 5.1. može se zaključiti da je prva navedena baza najpotpunija, ali 2 od 5 videosignala ne uključuju početni segment. Druga baza ima samo jedan videosignal. Treća i četvrta imaju samo 3 odnosno 4 videosignala dulja od 20 sekundi, a za ispitivanje algoritama za videostrujanje bi trebali biti duljine barem 60 do 120 sekundi. Zadnja i predzadnja baza uopće nemaju dostupne videosegmente. Sve baze osim zadnje imaju MPD u samo jednom ili dva profila. Ostale dostupne baze koje nisu ovdje navedene ne pružaju videosignale segmentirane prema MPEG DASH normi s početnim segmentom i odgovarajućim MPD datotekama. Također niti jedna od ovih baza nema u MPD-u dodatne informacije kao što je veličina segmenta niti su videosignali odabrani prema aktivnosti sadržaja.

Tablica 5.1. Usporedba dostupnih baza videosignala segmentiranih za korištenje u sustavima zasnovanim na MPEG DASH normi

Naziv baze	Broj video-signala	MPD Profil	Trajanje segmenta [s]	Broj reprezentacija	Segmentacija zasnovana na:	Kodek	Dostupnost segmenata
DASH [4]	5	Simple, On-Demand	1, 2, 4, 6, 10, 15	17-20	PSNR	AVC	Da
Distribuirani DASH [24]	1	Main, Live	2, 4, 6, 10, 15	17	N / A	AVC	Da
Baza kodirana SVC kodekom [67]	12 (8)	Main	2	4-12 po varijanti	N / A	SVC	Da
DASH baza s različitim kodecima [16]	10 (7)	Full	2, 4	19	pružatelji usluga i dostupna istraživanja	AVC, HEVC, VP9 i AV1	Da
Baza kodirana AVC (H.264) i HEVC (H.265) kodecima [112]	N / A zbog autor-skih prava	Full	2,4,6,8, 10	10	N / A	AVC, HEVC	Ne
Baza visoke prostorne rezolucije HEVC DASH [113]	1	*Main, On-Demand, Live, Live with bitstream switch*	2, 4, 6, 10, 20	13	N / A	HEVC	Ne

5.2. Opis predložene baze kodiranih i segmentiranih videosignala

Ideja baze videosignala predložene u okviru ovog doktorskog rada je riješiti sve prethodno navedene probleme. Baza videosignala segmentirana je prema predloženim metodama za odabir broja i parametara reprezentacija koji ostvaruje veće vrijednosti SSIM-a u odnosu na prethodno dostupna rješenja te je uz bazu dostupna detaljna metodologija i zapis funkcija za odabir razina kvalitete. Kako bi se baza mogla koristiti u sustavima zasnovanim na MPEG DASH normi duljina videosignala niti za jedan videosignal nije manja od 120 sekundi. Uz bazu segmentiranih videosignala koja je dostupna na sljedećoj poveznici: https://drive.google.com/drive/folders/12yZ8aO9yW2REjbdYrB7jx7qUzaoOjNHG?usp=sha

ring dostupni su i izvorni videosignali, početni segmenti potrebni za inicijalizaciju dekodera te MPD datoteke u pet različitih profila: *full, live, main, onDemand* i prošireni *live* profil. Baza se sastoji od šest videosignala, videosignala BBB korištenog u ispitivanju predloženih metoda te pet novih videosignala: *Butterfly* (BT), *Trainstation1* (TS1), *Trainstation2* (TS2), *L eaves* (LE) i *Pidgeons* (PG) (primjer slika is svakog vieodsignala dan je na slici 5.1). Videosignali su snimljeni videokamerom u .mov formatu u 3840×2160 prostornoj rezoluciji i vremenskoj rezoluciji 25 slika u sekundi te su duljine 120 s. Djelomične MPD datoteke za videosignal *Butterfly* (BT) za svaki profil prikazane su u prilozima P.1. do P.5. Prikazani su dijelovi MPD datoteka za trajanje segmenta deset sekundi.



a)



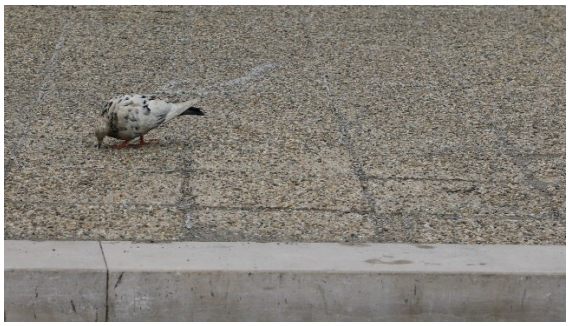
b)



c)



d)



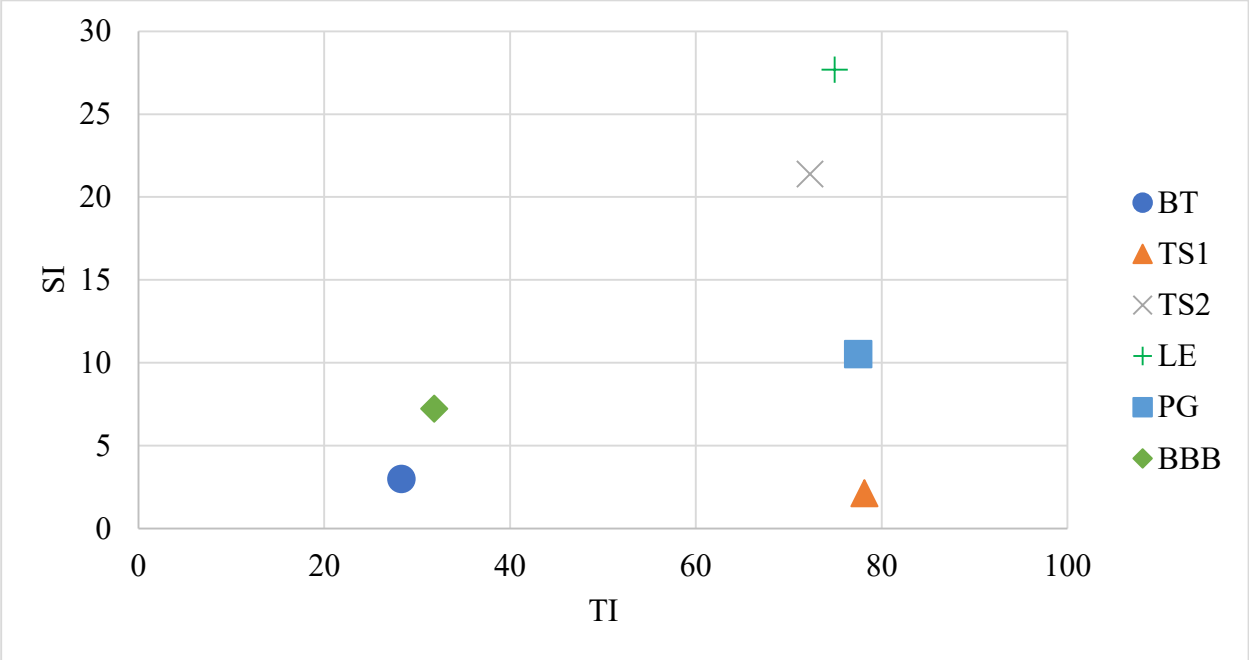
e)

Slika 5.1. Slike iz videosignala: a) *Butterfly* (BT), b) *Trainstation1* (TS1), c) *Trainstation2* (TS2), d) *Leaves* (LE), e) *Pidgeons* (PG)

Prostorne i vremenske informacije svih šest videosignala prikazane su u tablici 5.2. i slikom 5.2. Videosignali odabrani su upravo prema prostornim i vremenskim informacijama pa tako LE, TS2, PG i TS2 imaju vrijednosti TI oko 75, ali raspon vrijednosti SI je od 2,13 za TS1 do 27,68 za LE. BT i TS1 imaju vrijednost SI oko 2, ali različite vrijednosti TI.

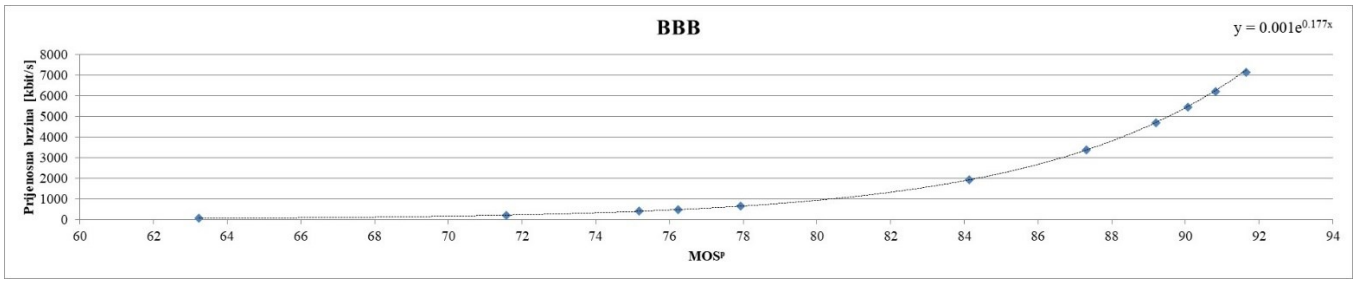
Tablica 5.2. Prostorne i vremenske informacije videosignala dostupnih u predloženoj bazi

Videosignal	BT	TS1	TS2	LE	PG	BBB
TI	28,32	78,16	72,28	74,97	77,50	31,84
SI	2,99	2,13	21,37	27,68	10,51	7,22
SITI	84,60	166,87	1545,04	2075,26	814,25	229,88

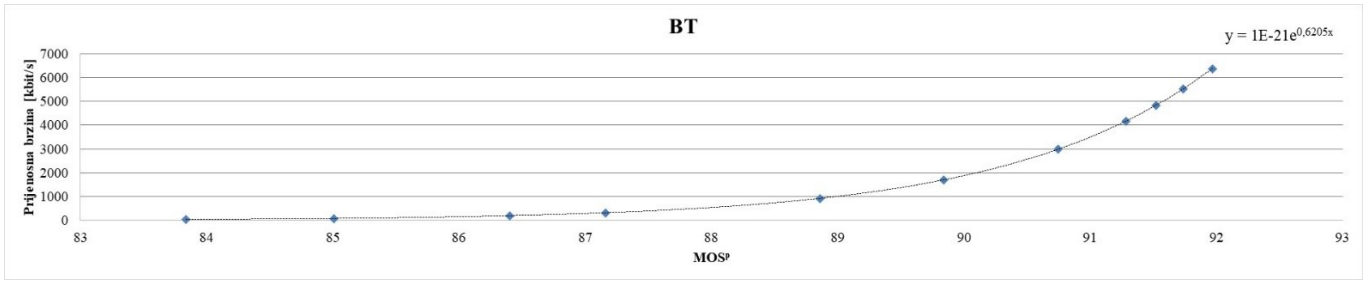


Slika 5.2. Prostorne i vremenske informacije videosignala dostupnih u predloženoj bazi

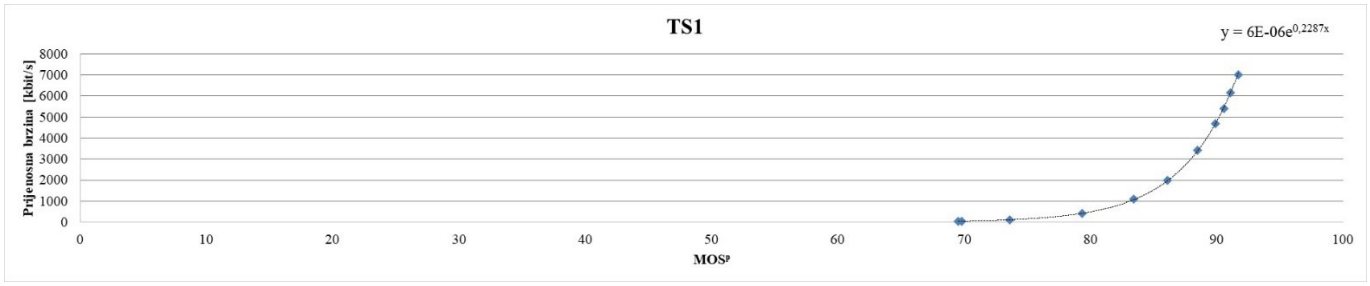
Videosignali kodirani su i segmentirani prema parametrima određenim izrazima (4-4), (4-7), (4-8) i (4-9). Krivulje ovisnosti prijenosne brzine o MOS vrijednostima prikazane su slikama 5.3. do 5.8. Kodne brzine i pripadajuće prostorne rezolucije za reprezentacije odabrane prema predloženim metodama za videosignal BBB prikazane su u tablici 4.15, a za preostale videosignale *Butterfly* (BT), *Trainstation1* (TS1), *Trainstation2* (TS2), *Leaves* (LE) i *Pidgeons* (PG) se nalaze u tablicama 5.3. do 5.7. Svi videosignali segmentirani su s trajanjem segmenta od 2, 6 i 10 sekundi. Videosignal BBB je duljine 9 minuta i 56 sekundi, a ostali videosignali imaju duljinu od 2 minute.



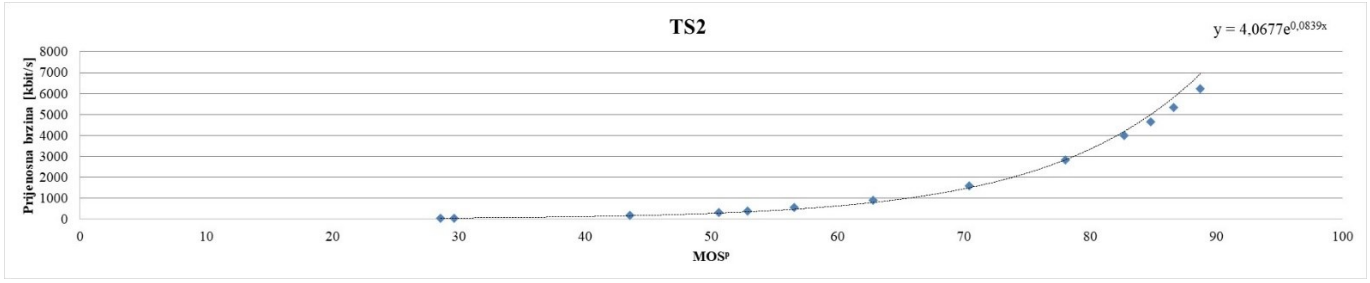
Slika 5.3. Krivulja ovisnosti prijenosne brzine o vrijednosti MOS^p za *Big Buck Bunny* (BBB)



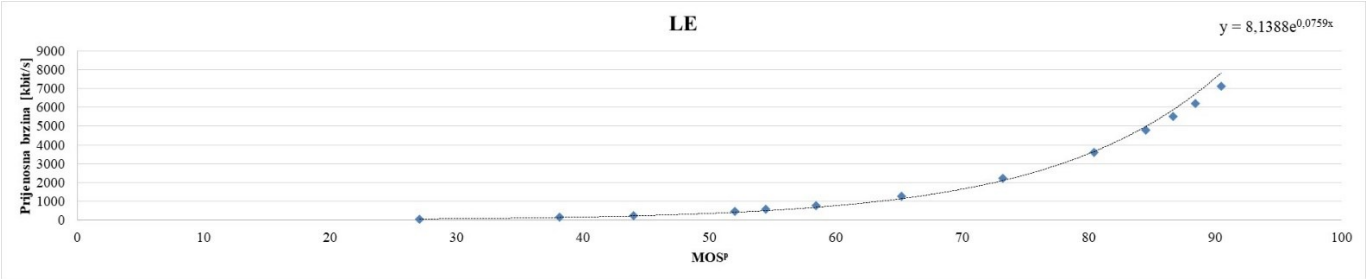
Slika 5.4. Krivulja ovisnosti prijenosne brzine o vrijednosti MOS^p za *Butterfly* (BT)



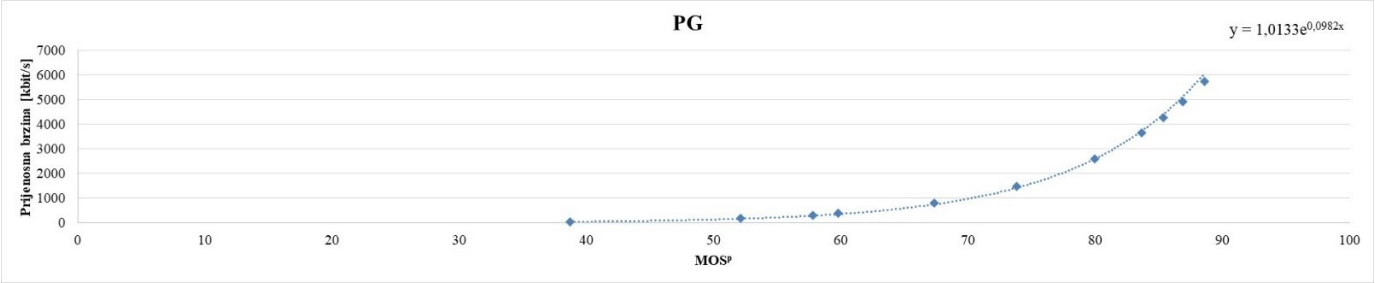
Slika 5.5. Krivulja ovisnosti prijenosne brzine o vrijednosti MOS^p za *Trainstation1* (TS1)



Slika 5.6. Krivulja ovisnosti prijenosne brzine o vrijednosti MOS^p za *Trainstation2* (TS2)



Slika 5.7. Krivulja ovisnosti prijenosne brzine o vrijednosti MOS^p za *Leaves* (LE)



Slika 5.8. Krivulja ovisnosti prijenosne brzine o vrijednosti MOS^p za *Pidgeons* (PG)

Tablica 5.3. Parametri reprezentacija videosignala *Butterfly* (BT)

Prijenosna brzina [kbit/s]	Prostorna rezolucija	Kodna brzina [kbit/s]
43,28	240p	50
80,50	360p	100
149,71		200
278,44	480p	350
517,86	720p	700
963,15	1080p	1500
1791,33		2500
3331,62		4500
6196,33		7800

Tablica 5.4. Parametri reprezentacija videosignala *Trainstation1* (TS1)

Prijenosna brzina [kbit/s]	Prostorna rezolucija	Kodna brzina [kbit/s]
47,00	240p	50
85,00	360p	100
134,30		150
212,18	480p	250
335,24		400
529,67	720p	650
836,85		1000
1322,20	1080p	1700
2089,02		2600
3300,56		4000
5214,76		6000
8239,12		9300

Tablica 5.5. Parametri reprezentacija videosignala *Trainstation2* (TS2)

Prijenosna brzina [kbit/s]	Prostorna rezolucija	Kodna brzina [kbit/s]
116,64	360p	150
150,02		200
192,96		250
248,19		300
319,22	480p	450
410,58		550
528,10		700
679,24		850
873,65	720p	1200
1123,70		1600
1445,31		2000
1858,97	1080p	3000
2391,03		3500
3075,36		4500
3955,56		5400
5087,68		6700
6543,83		8400

Tablica 5.6. Parametri reprezentacija videosignala *Leaves* (LE)

Prijenosna brzina [kbit/s]	Prostorna rezolucija	Kodna brzina [kbit/s]
169,46		200
212,80		250
267,21	360p	300
335,54		400
421,34		500
529,08		550
664,37	480p	750
834,26		1000
1047,58		1300
1315,46		1600
1651,84		2000
2074,22	720p	2400
2604,62		3000
3270,65		3800
4106,98		4700
5157,17		5800
6475,90		7300
8131,84	1080p	9000

Tablica 5.7. Parametri reprezentacija videosignala *Pidgeons* (PG)

Prijenosna brzina [kbit/s]	Prostorna rezolucija	Kodna brzina [kbit/s]
92,80		100
124,59		150
167,27		200
224,58	240p	250
301,51		350
404,81		450
543,49	360p	650
729,68		950
979,67		1200
1315,29	480p	1600
1765,89		2500
2370,87	720p	3200
3183,10		4800
4273,60		6200
5737,69		8000
7703,36	1080p	10000

6. OKVIR ZA ANALIZU I OPTIMIZACIJU PARAMETARA ALGORITAMA ZA VIDEOSTRUJANJE PRILAGODLJIVO MREŽNIM UVJETIMA ZASNOVANO NA MPEG DASH NORMI

Kvaliteta strujanja videosignala ovisi o uspjehu algoritma za prilagodbu prijenosne brzine (tj. odabira razine kvalitete) za svaki segment, ovisno o dostupnoj propusnosti mreže. Kada se dostupna propusnost mreže poveća ili smanji, algoritmi za prilagodbu prijenosne brzine primjenjuju različite strategije za promjenu razina kvalitete, a na uspjeh algoritama utječe i način na koji se procjenjuje dostupna propusnost. Cilj algoritama je osigurati što bolji QoE, odnosno smanjiti početno kašnjenje, pružiti najbolju moguću kvalitetu videosignala i izbjeći ili smanjiti broj prekida u reprodukciji videosignala. Prit tome optimizacija strujanja kod korištenja mobilnih mreža predstavlja posebno veliki izazov za algoritme za prilagodljivo videostrujanje zbog brzih i značajnih promjena u dostupnoj propusnosti.

Izmjereni mrežni ispitni zapisi za različite mreže obično se koriste u analizi algoritama za prilagodljivo videostrujanje. Iako se stvarne mreže najbolje mogu simulirati korištenjem izmjerenih mrežnih ispitnih zapisa, zbog velikih razlika statističkih svojstava mrežnih ispitnih zapisa izmjerenih u različito doba dana ili godine, kao i različitih ruta korisnika u mobilnim mrežama, one nisu u potpunosti prikladne za sustavnu analizu algoritama za prilagodljivo videostrujanje. U tu svrhu računalno generirani mrežni ispitni zapisi mogu biti prikladniji, pod uvjetom da dobro oponašaju realne mrežne ispitne zapise.

U dosadašnjim ispitivanjima utjecaja parametara kao što su početno kašnjenje, prosječna kvaliteta videosignala i broj prekida u reprodukciji videosignala na kvalitetu korisničkog iskustva, koristili su se većinom stvarni sustavi za strujanje te je kvaliteta videosignala ocijenjena subjektivnim i objektivnim metodama za ocjenu kvalitete videosignala nakon strujanja. Također na isti način su se i uspoređivali algoritmi za prilagodljivo videostrujanje. Problem kod ovakvog načina analize parametara koji utječu na kvalitetu videosignala je da ne postoji način kako analizirati utjecaj svakog pojedinačnog parametra i manipulirati vrijednostima istih. Također ovakvim načinom analize, vremenski je zahtjevno ispitati utjecaj parametara kodiranja i segmentacije videosignala na kvalitetu videosignala nakon strujanja jer svaka promjena u parametrima zahtjeva ponovnu segmentaciju videosignala, izradu MPD datoteke i postavljanje na poslužitelj. Kako bi se riješili navedeni problemi, ovo poglavlje opisuje okvir za analizu i optimizaciju parametara algoritama za videostrujanje prilagodljivo mrežnim uvjetima zasnovano na MPEG DASH normi koje ima mogućnost računalnog generiranja mrežnih ispitnih zapisa koji odgovaraju uvjetima u 3G i 4G mrežama.

6.1. Dostupna rješenja

U dostupnoj literaturi postoji nekoliko istraživanja koja su na tragu okvira opisanog u ovom poglavlju. Prvo dostupno rješenje razvijeno u početku razvoja sustava za videostrujanje, opisano je u [114] i predstavlja okvir za generiranje ispitnih videosignala koji se mogu koristiti za usporedbu modela za ocjenu kvalitete korisničkog iskustva. Okvir se može koristiti za generiranje ispitnih videosignala sa smanjenom kvalitetom koja se javlja zbog utjecaja parametara kodiranje videosignala, artefakata koji se javljaju zbog prijenosa videosignala kroz medij i gubitka paketa. Okvir kvalitetu dekodiranog videosignala ocjenjuje na mrežnom sloju.

Okvir za analizu vjerojatnosti trajanja početnog kašnjenja i pojave prekida u reprodukciji videosignala, popunjenosti međuspremnika i promjena u protoku TCP paketa opisan je u [115], a zasnovan je na predloženom modelu za TCP strujanje videosignala. Ideja predloženog okvira je poboljšati QoE analizom odnosa između brzine dolaska TCP paketa, popunjenosti međuspremnika i brzine reprodukcije videosignala.

Prvo dostupno rješenje primjenjivo na algoritme za prilagodljivo videostrujanje opisano u [116] je okvir za analizu prilagodljivog videostrujanja (engl. *Adaptive Video Streaming Evaluation* – AdViSE). AdViSE se koristi za ispitivanje uređaja i algoritama za prilagodljivo videostrujanje u promjenjivim mrežnim uvjetima. Glavna namjena AdViSE okvira je usporedba korisničkih uređaja za strujanje videosignala, ali se može koristiti i za usporedbu algoritama za prilagodljivo videostrujanje. AdViSE okvir na svom izlazu daje vrijednosti skupa QoS i QoE parametara.

Sljedeći okvir dostupan u literaturi je proširena verzija AdViSE okvira koja osim AdViSE okvira uključuje i platformu za subjektivnu ocjenu kvalitete videosignala (engl. *Web-based Subjective Evaluation Platform* - WESP) [117] te dodatna proširenja. WESP je mrežna platforma za subjektivnu ocjenu kvalitete videosignala koja koristi više postojećih mrežnih platformi za pronalaženje gledatelja za ocjenu kvalitete videosignala. Izlazne vrijednosti iz WESP platforme uključuju neobrađene subjektivne ocjene i MOS vrijednosti. Okvir predložen u [118] tako na svom izlazu daje i vrijednosti skupa QoS i QoE parametara iz AdViSE okvira i subjektivne ocjene i MOS vrijednosti iz WESP platforme koji se zatim mogu koristiti za daljnju analizu.

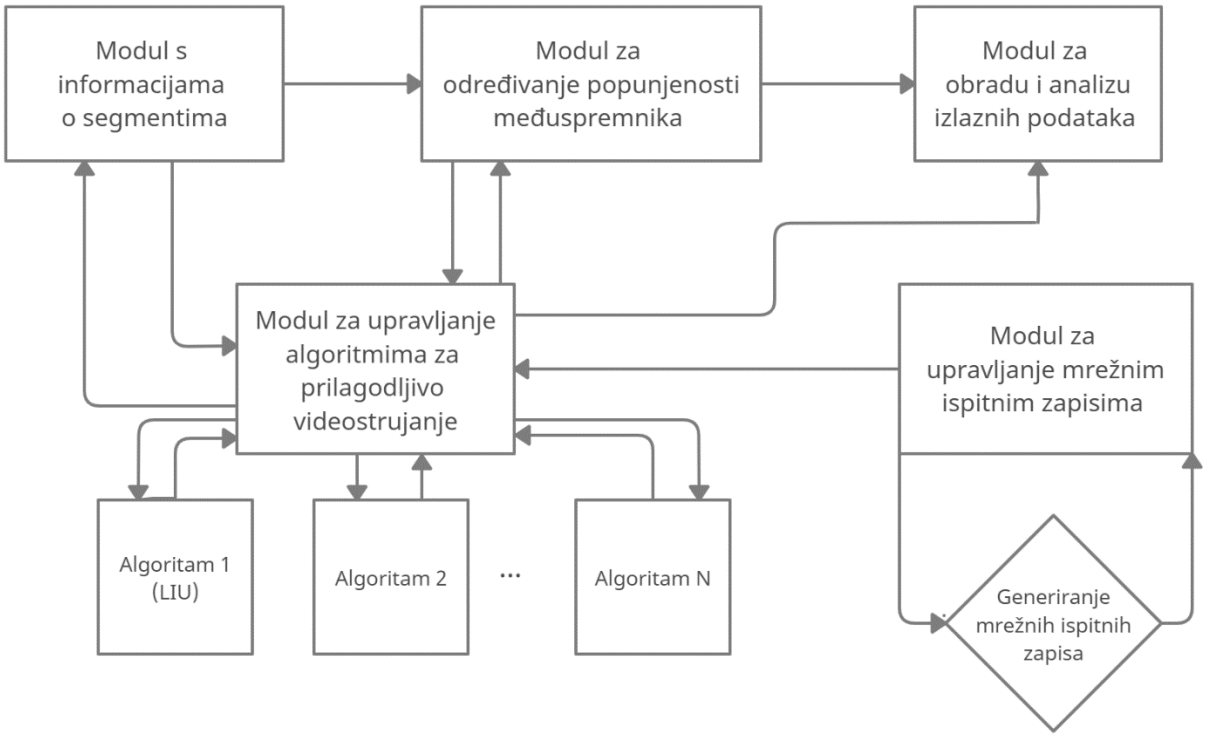
Rješenje slično [116] opisano je u [19]. Predloženi okvir je kao i prethodna dva opisana okvira ima mogućnost usporedbe algoritama za prilagodljivo videostrujanje u stvarnim uvjetima u mreži jer se radi o okviru koji prikuplja podatke koji se šalju između poslužitelja i korisničke aplikacije. Opisani okvir predstavlja poboljšanje u odnosu na okvir opisan u [116] jer ima mogućnost analize podataka koji se dohvaćaju HTTPS-om. Za razliku od okvira opisanog u [118], okvir opisan u

[119] nema mogućnost ocjene kvalitete videosignala nego se samo koristi za prikupljanje vrijednosti parametara QoE, početnog kašnjenja i trajanja prekida u reprodukciji, koji se mogu kasnije obrađivati. Opisani okvir se također može koristiti za generiranje baze podataka prikupljenih analizom videostrujanja i analizu korisničkih aplikacija. Upravljanje mrežnim uvjetima izvršeno je pomoću programa za ograničavanje mrežne dostupnosti slično kao što je korišteno u ispitivanju algoritama za videostrujanje u trećem poglavlju ove disertacije.

Sva prethodno opisana rješenja koja se mogu koristiti za analizu sustava za videostrujanje, rade na način da analiziraju videostrujanje stvarnih sustava tako da mjere mrežne parametre, popunjenost međuspremnika, početno kašnjenje i trajanje zastoja u reprodukciji videosignala slično kao što rade i sami algoritmi za prilagodljivo videostrujanje, ali nemaju mogućnost manipulacije pojedinih parametara kvalitete korisničkog iskustva kao ni mogućnost promjene parametara i generiranja skupa mrežnih zapisa koji odgovaraju uvjetima u 3G i 4G mrežama.

6.2. Opis okvira za analizu i optimizaciju parametara algoritama za videostrujanje prilagodljivo mrežnim uvjetima zasnovano na MPEG DASH normi

Okvir za analizu i optimizaciju parametara algoritama za videostrujanje prilagodljivo mrežnim uvjetima zasnovano na MPEG DASH normi koje ima mogućnost računalnog generiranja mrežnih ispitnih zapisa koji odgovaraju uvjetima u 3G i 4G mrežama razvijen je u Matlabu. Predloženi okvir može se koristiti za sustavnu analizu algoritama za prilagodljivo videostrujanje pomoću izmjerenih, ali i umjetno generiranih mrežnih ispitnih zapisa. Shematski prikaz predloženog okvira prikazan je na slici 6.1. Okvir se temelji na MPEG DASH normi, koja definira da svaki videosignal treba biti kodiran i segmentiran prije videostrujanja te su parametri reprezentacija i veličine segmenata ulazni parametri okvira. Razvijeni simulacijski okvir sastoji se od modula s informacijama o segmentima, modula za određivanje statusa međuspremnika (prilog P.6.), modula koji sadrži algoritam za prilagodljivo videostrujanje (prilog P.7.), modula za definiranje mrežnih uvjeta (prilozi P.8. i P.9.) i modula za obradu i analizu izlaznih podataka (prilog P.10. i P.11.).



Slika 6.1. Shematski prikaz okvira za analizu i optimizaciju parametara algoritama za videostrujanje prilagodljivo mrežnim uvjetima zasnovano na MPEG DASH normi

Modul s informacijama o segmentima sadrži podatke videosegmenata kao što su prijenosne brzine na zadanoj razini kvalitete, prostorne i vremenske rezolucije, stvarne ili procijenjene veličine segmenata, trajanje segmenata i kvaliteta iskazana u SSIM vrijednostima (ili nekoj drugoj objektivnoj metrici). Za potrebe analize predstavljene u ovom radu korišteni su podaci dobiveni kodiranjem i segmentiranjem videosignala *Big Buck Bunny* i *El Fuente Mask* za segmente s trajanjem od 6 sekundi. Za potrebe ispitivanja umjetno generiranih mrežnih ispitnih zapisa i točnosti samog okvira, korišten je BBB videosignal kodiran i segmentiran u 20 reprezentacija prema Lederer segmentaciji. Prijenosne brzine postignute ovom segmentacijom za 3G mrežu su od 45 kbit/s na najnižoj razini kvalitete do 3858 kbit/s na najvišoj razini kvalitete.

Za simulaciju 4G mreže, prijenosne brzine za različite razine kvalitete bile su između 450 kbit/s i 38580 kbit/s. Predloženi okvir ima mogućnost korištenja različitih algoritama za prilagodljivo videostrujanje, a rezultati u ovom poglavlju su dani za simulacije videostrujanja korištennjem LIU algoritma za prilagodljivo videostrujanje.

Modul za određivanje statusa međuspremnika dio je simulacijskog okvira koji izračunava trenutnu popunjenost međuspremnika. U provedenim simulacijama postavljeno je da je jedan videosegment minimalna početna količina podataka koja treba biti preuzeta i biti pohranjena u međuspremnik prije početka reprodukcije videosignala.

Modul za definiranje mrežnih uvjeta omogućuje upotrebu različitih mrežnih ispitnih zapisa u svrhu simulacije. U poglavlju 6.4. predstavljeni su rezultati simulacija u kojima je korišteno 20 odabranih mrežnih ispitnih zapisa izmjerenih u 3G i 4G mrežama, kao i umjetno generirani mrežni ispitni zapisi s parametrima jednakim odabranim izmjerenim mrežnim ispitnim zapisima.

Modul za obradu i analizu izlaznih podataka kao izlazne podatke predloženog okvira daje vrijednosti sljedećih parametara: početno kašnjenje, prosječna razina kvalitete videosignala nakon videostrujanja (prosjek razina kvalitete preuzetih videosegmenata), prosječna odabrana prijenosna brzina (prosjek odabranih prijenosnih brzina za sve preuzete videosegmente), broj prebacivanja razina kvalitete, prosječna dubina prebacivanja razina kvalitete (prosjek razlika između razina kvalitete za sukcesivne videosegmente), broj i trajanje prekida u reprodukciji videosignala.

Videosignali su u predloženom okviru modelirani kao skup uzastopnih segmenata, $Nuk = \{N_1, N_2, \ldots, Nuk\}$. Svaki je videosegment trajanja Ts i dostupan je u $Ruk = \{R_1, R_2, \ldots, Ruk\}$ različitih prijenosnih brzina, PB. Algoritam za prilagodljivo videostrujanje odabire reprezentaciju R za svaki pojedini videosegment N ($N \in Nuk$). Veličina segmenta N ako je korišteno kodiranje CBR može se procijeniti izrazom (6-1).

$$Ds(N,R) = Ts \cdot PB(R) \tag{6-1}$$

$Vs(N)$ je vektor veličina segmenata pohranjenih u međuspremniku ($Buff$) potreban za proračun pražnjenje međuspremnika. Videosegmenti se preuzimaju u međuspremnik za reprodukciju koji sadrži preuzete videosegmente. Popunjenost međuspremnika, $Buff$ u trenutku t (iskazano kao preostalo vrijeme reprodukcije videosignala u međuspremniku) dano je izrazom (6-2) .

$$Buff_{full} = Buff_{all(N)} \cdot Ts \tag{6-2}$$

U trenutku $Buff_{full} = Ts$ započinje reprodukcija videosignala i pražnjenje međuspremnika.

Vrijeme potrebno za preuzimanje videosegmenta N određeno je izrazom (6-3).

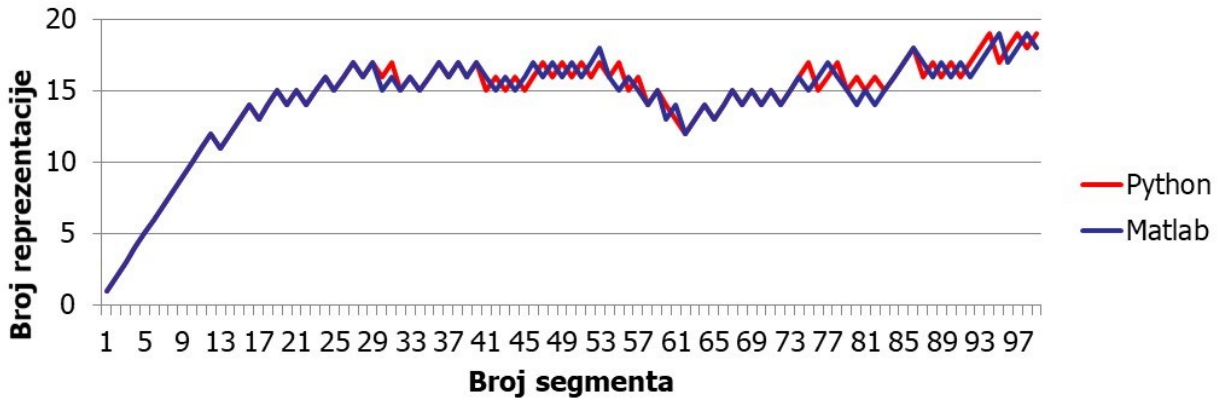
$$Dt(N,R) = Ds(N,R) \,/PB(R) \tag{6-3}$$

Popunjenost međuspremnika, *Buff* povećava se za *Ts* kako se preuzima svaki novi videosegment i smanjuje kako se reproducira videosignal. Ako je $Buff_N = Buffer_{full}$, dinamika međuspremnika može se odrediti izrazom (6-4) gdje je T_N srednja propusnost korištena za preuzimanje videosegmenta *N*.

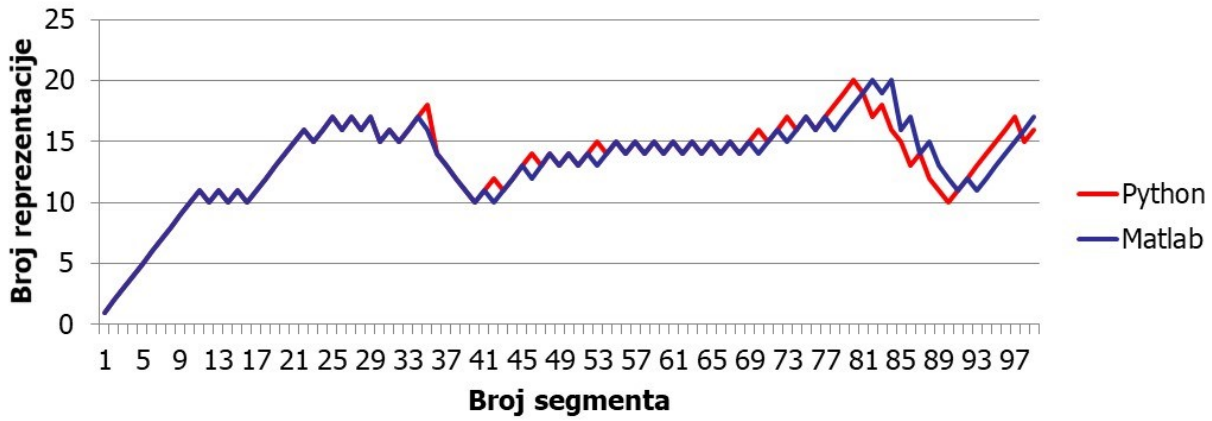
$$Buff_{N+1} = Buff_N - \frac{Ds(N,R)}{T_N} + Ts \tag{6-4}$$

Pretpostavljeno je da se segment *N+1* odmah počinje preuzimati čim se preuzme segment *N*.

Slikama 6.2. i 6.3. prikazane su krivulje odabranih razina kvalitete pomoću predloženog okvira i stvarnog sustava opisanog u [111] određene u svrhu ispitivanja točnosti predloženog okvira. Za potrebe ispitivanja korišten je LIU algoritam i dva mrežna ispitna zapisa. U prvom mrežnom ispitnom zapisu, srednja dostupna propusnost bila je 7 Mbit/s, a dostupna se propusnost mijenjala postupno. U drugom mrežnom ispitnom zapisu, srednja dostupna propusnost bila je 4,5 Mbit/s, a dostupna se propusnost mijenjala postupno uz nekoliko naglih smanjenja dostupne propusnosti. Kao što je vidljivo iz slika 6.2. i 6.3, za oba mrežna ispitna zapisa dolazi do minimalnih odstupanja u vrijednostima odabranih razina kvalitete za videosignal BBB prilikom usporedbe predloženog okvira i stvarnog sustava opisanog u [111] (Python). PLCC vrijednosti izračunate za prikupljene podatke su 0,978 i 0,953 iz kojih se može zaključiti da predloženi okvir s velikom točnošću simulira stvarni sustav. Do malih odstupanja dolazi zbog nemogućnosti reprodukcije stvarnih mrežnih uvjeta u Matlab-u jer osim postavljenog mrežnog ispitnog zapisa, u stvarnom sustavu na dostupnu propusnost utječu i parametri samog računala kao što je brzina zapisa na memorijski uređaj.



Slika 6.2. Krivulje odabranih razina kvalitete pomoću predloženog okvira i stvarnog sustava opisanog u [111] određene u svrhu ispitivanja točnosti predloženog okvira (prvi mrežni ispitni zapis)



Slika 6.3. Krivulje odabranih razina kvalitete pomoću predloženog okvira i stvarnog sustava opisanog u [111] određene u svrhu ispitivanja točnosti predloženog okvira (drugi mrežni ispitni zapis)

6.3. Umjetno generiranje ispitnih zapisa

Većina dostupnih istraživanja usredotočena je na poboljšanje algoritama za prilagodljivo videostrujanje koji se obično ispituju ili pomoću pojednostavljenih umjetno generiranih mrežnih ispitnih zapisa ili pomoću mrežnih ispitnih zapisa iz jedne od dostupnih baza podataka s izmjerenom propusnošću. Iako izmjereni mrežni ispitni zapisi najbolje opisuju stvarne uvjete u mreži, zbog velike raznolikosti njihovih statističkih svojstava i ograničene dostupnosti, nisu u potpunosti prikladni za sustavnu analizu algoritama za prilagodljivo videostrujanje. Za sustavne analize mogu se koristiti i računalno generirani mrežni ispitni zapisi mijenjanjem njihovih parametara, pod uvjetom da dobro oponašaju stvarne mrežne ispitne zapise. Analizom dostupnih istraživanja, utvrđeno je da nema mnogo objavljenih istraživanja koja analiziraju računalno generirane mrežne ispitne zapise, najprikladnije raspodjele vjerojatnosti pomoću kojih je moguće analizirati mrežne ispitne zapise i odabrati optimalne parametre.

Računalno generirani mrežni ispitni zapisi istraženi su u [120-121]. Uzimajući u obzir da su izmjereni mrežni ispitni zapisi analizirani u [120-121] slijedili Gauss-ovu distribuciju, dostupna propusnost modelirana je korištenjem broja korisnika koji dijele usko grlo (engl. *bottleneck*) mijenjanjem matrice vjerojatnosti prijelaza stanja te parametara srednje vrijednosti i varijance iz Gauss-ove raspodjele vjerojatnost. Nažalost, u istraživanju opisanom [120] ne postoje detaljne informacije poput parametara koji se koriste za računalno generiranje mrežnih ispitnih zapisa.

Rezultati analize nadogradnje za 5G mreže za okvir predložen u istraživanju opisanom u [121] koji je razvijen za 4G mreže dani su u [122]. I u ovom je slučaju korištena Gauss-ova raspodjela vjerojatnosti za analizu dostupnih izmjerenih mrežnih ispitnih zapisa. Ideja ovog okvira bila je stvoriti umjetno generirane mrežne ispitne zapise koji su prilagodljivi i fleksibilni. Izlazni se mrežni ispitni zapisi sastoje od vremenskih pokazatelja kvalitete i dostupne propusnosti. Predloženi okvir pruža podatke u okruženju s direktnom vidljivosti mobilne i bazne postaje (engl. *Line of Sight*) za određeni broj 5G baznih stanica i korisnika.

S obzirom na to da postoji ograničena količina dostupnih mrežnih ispitnih zapisa koji se mogu koristiti za analizu utjecaja različitih parametara poput početnog kašnjenja, broja i trajanja prekida u reprodukciji videosignala i broja prebacivanja razina kvalitete prilikom usporedbe različitih algoritama za prilagodljivo videostrujanje, cilj dijela istraživanja bio je napraviti statističku analizu reprezentativnih izmjerenih mrežnih ispitnih zapisa i predložiti model za računalno generiranje mrežnih ispitnih zapisa s realnim karakteristikama koji će biti implementiran u predloženi okvir za analizu i optimizaciju parametara algoritama za videostrujanje prilagodljivo mrežnim uvjetima zasnovano na MPEG DASH normi.

6.3.1. Analiza 3G i 4G baze ispitnih zapisa pomoću Nakagami raspodjele

Analiza histograma izmjerenih mrežnih ispitnih zapisa za 3G i 4G mreže pokazala je da njihov oblik značajno varira, od Gaussovog do opadajućeg eksponencijalnog oblika. Nakagami raspodjela vjerojatnosti odabrana je kao teorijski model za opisivanje statističkog ponašanja dostupne propusnosti u mobilnim mrežama jer može opisati različite oblike histograma. Nakagami raspodjela vjerojatnosti često se koristi za modeliranje anvelope prijamnog signala u uvjetima višestaznog slabljenja signala (engl. *multipath fading*) u mobilnim komunikacijama, gdje se snaga primljenog signala vrlo brzo mijenja uz velike oscilacije. Brze i velike oscilacije također su karakteristične za izmjerene propusnosti u mobilnim mrežama. Dijelom je to uzrokovano brzim promjenama primljenog signala, ali na postignutu propusnost utječu i drugi čimbenici, poput dostupne propusnosti u određenoj ćeliji te prometa drugih korisnika.

U svakom slučaju, statistika izmjerenih mrežnih ispitnih zapisa pokazuje da Nakagami raspodjela vjerojatnosti može biti dobar izbor za njihovo modeliranje. Nakagami funkcija gustoće vjerojatnosti dana je izrazom (6-5) [123].

$$f(x) = \frac{2}{\Gamma(m)} \left(\frac{m}{\omega}\right)^m x^{2m-1} e^{-\frac{m}{\omega} x^2} \tag{6-5}$$

gdje je X pozitivna slučajna varijabla, m parametar oblika, a ω parametar širenja. Nakagami raspodjela vjerojatnosti definirana je za $m > 0{,}5$ i $\omega > 0$. Parametri Nakagami raspodjele vjerojatnosti definiraju srednju vrijednost i varijancu Nakagami slučajne varijable X prema izrazima (6-6), odnosno (6-7), [123].

$$E(X) = \frac{\Gamma(m+\frac{1}{2})}{\Gamma(m)} \sqrt{\frac{\omega}{m}} \tag{6-6}$$

$$Var(X) = E(X^2) - E(X)^2 = \omega \left[1 - \frac{1}{m} \left(\frac{\Gamma(m+\frac{1}{2})}{\Gamma(m)} \right)^2 \right] \tag{6-7}$$

gdje $\Gamma(\bullet)$ predstavlja *gamma* funkciju. Parametri m i ω mogu se odrediti pomoću izraza (6-8), odnosno (6-9)

$$m = \frac{E(X^2)^2}{Var(X^2)} \tag{6-8}$$

$$\omega = E(X^2) \tag{6-9}$$

U slučaju kada je $m = 1$, Nakagami raspodjela jednaka je Rayleigh-ovoj raspodjeli, a u slučaju kada je $m = 0{,}5$ jednaka je jednostranoj Gauss-ovoj raspodjeli [123].

3G skup mrežnih ispitnih zapisa

Za statističku analizu izmjerene propusnosti u 3G mrežama korištena je javno dostupan skup podataka koja se sastoji od mjerenja prikupljenih tokom strujanja videosignala korištenjem HTTP-a preko 3G mreže pomoću mobilnih uređaja, [124]. Različite vrste javnog prijevoza u Oslu (Norveška) poput automobila, vlaka, tramvaja, autobusa, trajekta i metroa korištene su za prikupljanje 86 mrežnih ispitnih zapisa. Mrežni ispitni zapisi pohranjeni su kao tekstualne datoteke koje sadrže sljedeće informacije: vremenske oznake, GPS koordinate i dostupnu propusnost izmjerenu kao broj bajtova preuzetih za približno svaku sekundu rute.

Za mrežne ispitne zapise izmjerene pomoću metroa, protok je bio nešto veći od 1 Mbit/s u slučajevima kada je metro bio iznad zemlje. Prosječna izmjerena propusnost za mrežne ispitne zapise za autobus bila je 2 Mbit/s. Za mrežne ispitne zapise izmjerene za trajekt, propusnost je bila najveća kada je trajekt bio blizu kopna, a prosječna propusnost bila je 2 Mbit/s. Tijekom korištenja tramvaja, propusnost je rijetko bila veća od 1 Mbit/s. Tijekom korištenja vlaka, maksimalna izmjerena propusnost bila je 3 Mbit/s, ali u izmjerenim uzorcima bilo je mnogo promjena u dostupnoj propusnosti. Konačno, mrežni ispitni zapisi za automobil imaju prosječnu izmjerenu

propusnost od 1 Mbit/s s maksimalnim vrijednostima preko 3 Mbit/s. Ovaj skup podataka korišten je za analizu i usporedbu utjecaja različitih mrežnih uvjeta na algoritme za prilagodljivo videostrujanje u mrežnim uvjetima s malom dostupnom propusnosti [72].

4G skup mrežnih ispitnih zapisa

Statistička analiza izmjerenih mrežnih ispitnih zapisa 4G / LTE mreže izvršena je na skupu podataka koji je nastao mjerenjem stvarnih mrežnih uvjeta u Gentu (Belgija), [125]. Skup podataka sastoji se od ukupno 40 mrežnih ispitnih zapisa. Kao i u 3G skupu podataka, nekoliko vrsta prijevoza poput autobusa, vlaka, tramvaja, automobila i bicikla korišteno je za prikupljanje podataka o postignutoj propusnosti izmjerenoj svake sekunde na zadanim rutama. Također su dostupni i mrežni ispitni zapisi izmjereni za pješake.

Niže vrijednosti mrežnih ispitnih zapisa izmjerene su u slučajevima kada je mjerenje provedeno u područjima s velikim zgradama ili tunelima. Primjerice, prosječna propusnost izmjerena u vlaku bila je 22,8 ± 14,5 Mbit/s, a u automobilu 33,9 ± 15,8 Mbit/s.

Procijenjeni parametri za 3G i 4G skup podataka

Istraživanje vezano uz računalno generiranje mrežnih ispitnih zapisa započeto je statističkom analizom odabranog skupa izmjerenih mrežnih ispitnih zapisa za 3G i 4G mreže. Rezultati srednje propusnosti, standardne devijacije propusnosti, kao i procijenjeni parametri m i ω odgovarajuće Nakagami funkcije gustoće vjerojatnosti prikazani su u tablici 6.1. za 3G mrežne ispitne zapise i tablici 6.2. za 4G mrežne ispitne zapise.

Tablica 6.1. Parametri izmjerenih mrežnih ispitnih zapisa za 3G mrežu

3G mrežni ispitni zapis	**Srednja propusnost [kbit/s]**	**Standardna devijacija propusnosti [kbit/s]**	**Procijenjeni Nakagami parametri**	
			m	**ω**
Autobus-1	2618	1176	1.166	$8.237 \cdot 10^6$
Autobus-2	1832	874	0.382	$3.746 \cdot 10^6$
Autobus-3	1720	908	0.983	$3.782 \cdot 10^6$
Autobus-4	2292	1173	0.929	$6.628 \cdot 10^6$
Autobus-5	2530	1096	1.310	$7.597 \cdot 10^6$
Tramvaj-1	778	354	1.167	$0.731 \cdot 10^6$
Tramvaj-2	680	366	0.959	$0.596 \cdot 10^6$
Tramvaj-3	740	401	0.810	$0.708 \cdot 10^6$
Tramvaj-4	764	439	0.720	$0.776 \cdot 10^6$
Tramvaj-5	839	453	0.936	$0.910 \cdot 10^6$
Vlak-1	1125	960	0.458	$2.159 \cdot 10^6$
Vlak-2	1403	807	0.718	$2.621 \cdot 10^6$
Vlak-3	1395	960	0.578	$2.867 \cdot 10^6$
Vlak-4	1465	1010	0.521	$3.165 \cdot 10^6$
Vlak-5	1408	860	0.686	$2.721 \cdot 10^6$
Automobil-1	727	832	0.262	$1.221 \cdot 10^6$
Automobil-2	727	786	0.249	$1.146 \cdot 10^6$
Automobil-3	1890	923	1.114	4.42410^6
Automobil-4	1901	996	0.926	$4.605 \cdot 10^6$
Automobil-5	1996	1173	0.783	$5.357 \cdot 10^6$

Tablica 6.2. Parametri izmjerenih mrežnih ispitnih zapisa za 4G mrežu

4G mrežni ispitni zapis	Srednja propusnost [kbit/s]	Standardna devijacija propusnosti [kbit/s]	Procijenjeni Nakagami parametri	
			m	**ω**
Autobus-1	27602	10354	1.829	$0.869 \cdot 10^9$
Autobus-2	30729	13474	0.995	$1.126 \cdot 10^9$
Autobus-3	19693	11171	0.565	$0.512 \cdot 10^9$
Autobus-4	40469	16285	1.220	$1.902 \cdot 10^9$
Tramvaj-1	21630	15965	0.542	$0.722 \cdot 10^9$
Tramvaj-2	14053	11495	0.302	$0.329 \cdot 10^9$
Tramvaj-3	35525	10978	1.475	$1.382 \cdot 10^9$
Tramvaj-4	37932	13862	1.334	$1.631 \cdot 10^9$
Vlak-1	23083	13893	0.472	$0.726 \cdot 10^9$
Vlak-2	24007	15071	0.470	$0.803 \cdot 10^9$
Vlak-3	21262	14606	0.334	$0.665 \cdot 10^9$
Bycicle-1	31566	12575	1.602	$1.154 \cdot 10^9$
Bycicle-2	25441	16541	0.500	$0.920 \cdot 10^9$
Automobil-1	35758	21779	0.495	$1.752 \cdot 10^9$
Automobil-2	29618	13890	1.058	$1.070 \cdot 10^9$
Automobil-3	28839	14210	0.878	$1.033 \cdot 10^9$
Automobil-4	36905	12314	2.229	$1.513 \cdot 10^9$
Pedestrian-1	41564	13395	2.400	$1.907 \cdot 10^9$
Pedestrian-2	17542	12151	0.498	$0.455 \cdot 10^9$
Pedestrian-3	31671	13057	0.853	$1.173 \cdot 10^9$
Pedestrian-4	17814	5643	1.760	$0.345 \cdot 10^9$

Za 3G mrežu odabrano je 20 mrežnih ispitnih zapisa koji predstavljaju tipične mrežne ispitne zapise izmjerene korištenjem autobusa, tramvaja, vlaka i automobila, dok je za 4G mrežu odabran 21 mrežni ispitni zapis s izmjerenim podacima za autobus, vlak, tramvaj, bicikl, automobil i pješake. Za 3G mrežne ispitne zapise, vrijednosti srednje propusnosti su od 680 kbit/s do 2618 kbit/s, a vrijednosti standardne devijacije su od 354 kbit/s do 1176 kbit/s. Vrijednosti parametra *m* su od 0,249 do 1,167, što je u skladu s uočenim velikim razlikama u obliku histograma odabranih mrežnih ispitnih zapisa. Srednja vrijednost propusnosti za 4G mrežu je od 14053 kbit/s do 41564

kbit/s, standardne devijacija je od 5643 kbit/s do 21779 kbit/s, a parametar *m* ima vrijednost od 0,302 do 2,4. Podaci prikazani u tablicama 6.1. i 6.2. pokazuju da se statistički parametri mrežnih ispitnih zapisa u mrežama 3G i 4G značajno razlikuju.

Uz procjenu parametara Nakagami raspodjele za stvarne mrežne ispitne zapise iz dostupnih skupova podataka, analizirane su i njihove funkcije autokorelacije. Utvrđeno je da postoji visoka korelacija veća od 0,9 između uzoraka uzetih u razmaku od oko 5 do 20 sekundi, ovisno o mrežnom ispitnom zapisu. Kako bi se uvela korelacija i u umjetno generirani mrežni ispitni zapis koji se sastoji od slučajnih brojeva s odgovarajućom Nakagami raspodjelom, primijenjeno je filtriranje filtrom pokretnog prosjeka (engl. *Moving Average* - MA) generiranih vremenskih nizova.

S obzirom da MA filtriranje smanjuje varijancu slučajnih nizova za faktor *K*, gdje je *K* broj koeficijenata MA filtra, pri generiranju mrežnog zapisa potrebno je prvo generirati niz brojeva s varijancom K puta većom od one koju treba imati taj mrežni zapis u konačnici. Stoga se slučajni brojevi prvo generiraju pomoću Nakagami parametara m_{corr} i ω_{corr}, koji su izvedeni iz parametara *m* and ω, procijenjenim za odgovarajuće stvarne mrežne ispitne zapise. Korištenjem (6-6), (6-7) i (6-9) i sljedećih pretpostavki:

$$E(X_{corr}) = E(X) \tag{6-10}$$

$$Var(X_{corr}) = K \cdot Var(X) \tag{6-11}$$

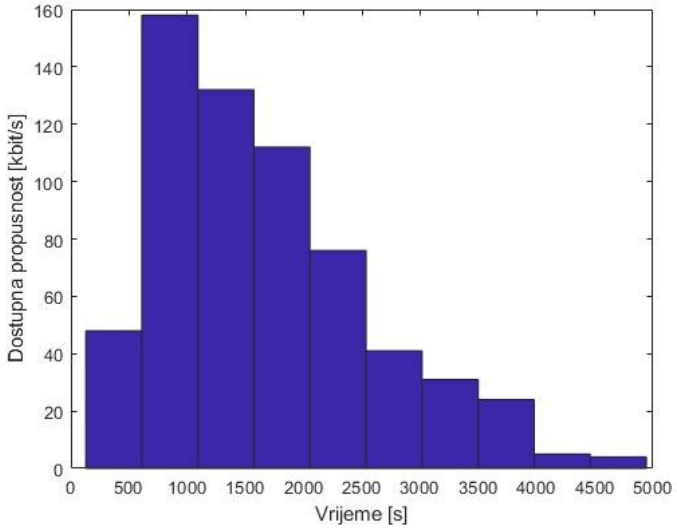
mogu se odrediti parametri m_{corr} i ω_{corr} prema sljedećim izrazima:

$$\omega_{corr} = K \cdot \omega + \left[\frac{\Gamma\left(\mathrm{m}+\frac{1}{2}\right)}{\Gamma(\mathrm{m})}\right]^2 \cdot \frac{\omega}{m} \cdot (K-1) \tag{6-12}$$

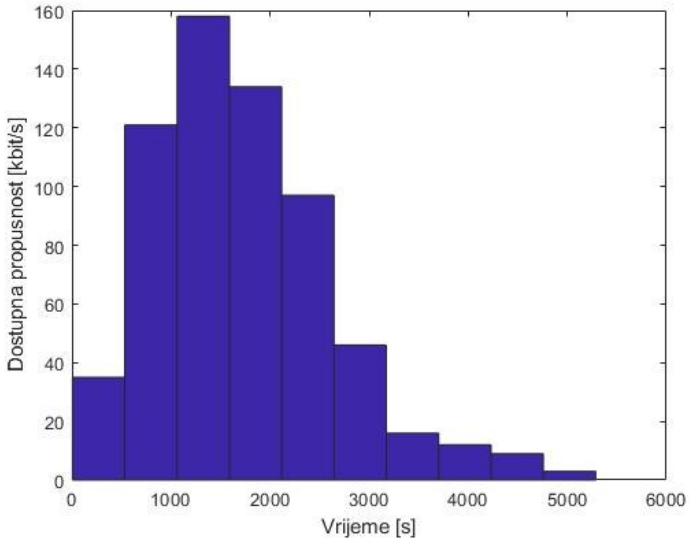
$$\frac{m_{corr} \cdot \left[\Gamma\left(m_{corr}+\frac{1}{2}\right)\right]^2}{[\Gamma(m_{corr})]^2} = \frac{m \cdot \omega_{corr}\left[\Gamma\left(m+\frac{1}{2}\right)\right]^2}{\omega \cdot [\Gamma(m)]^2} \tag{6-13}$$

Nakon MA filtriranja slučajnog niza koji se sastoje od X_{corr} vrijednosti, mrežni ispitni zapisi imaju Nakagami parametre *m* i ω jednake odgovarajućim izmjerenim mrežnim ispitnim zapisima. Kao primjer predloženog pristupa, slike 6.4. i 6.5. prikazuju histogram i vremenski prikaz propusnosti izmjerenog 3G mrežnog ispitnog zapisa Autobus-3, kao i histogram te vremenski prikaz propusnosti mrežnog ispitnog zapisa generiranog u Matlabu s istim Nakagami parametrima (m=0.983 i ω=3.782·10^6). Slike 6.6. i 6.7. prikazuju histograme i vremenske prikaze propusnosti izmjerenog 3G mrežnog ispitnog zapisa Autobus-5 i umjetno generiranog mrežnog ispitnog zapisa s Nakagami parametrima (m=1.310 i ω=7.597.10^6). Histogrami i vremenski prikazi propusnosti

nisu isti za izmjerene i generirane mrežne ispitne zapise, ali to je i očekivano. Svaki put kada se generiraju slučajni brojevi dobiju se i različiti histogrami i vremenski nizovi, unatoč istim Nakagami parametrima i statističkim parametrima kao što su srednja vrijednost i standardna devijacija.

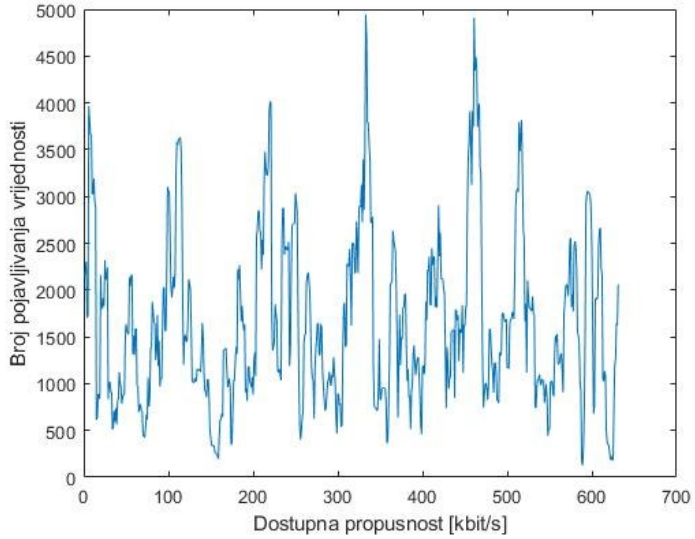


a)

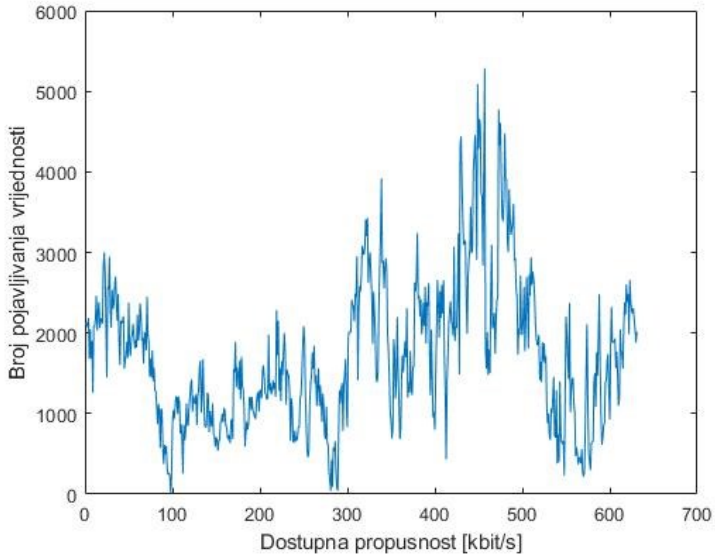


b)

Slika 6.4. a) Histogram 3G mrežnog ispitnog zapisa Autobus-3; b) histogram umjetno generiranog mrežnog ispitnog zapisa s parametrima m=0.983 i ω=3 782 106;

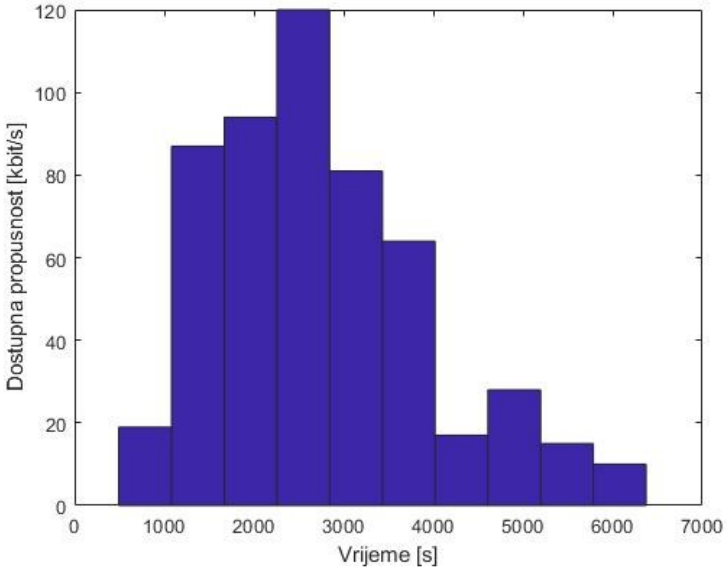


a)

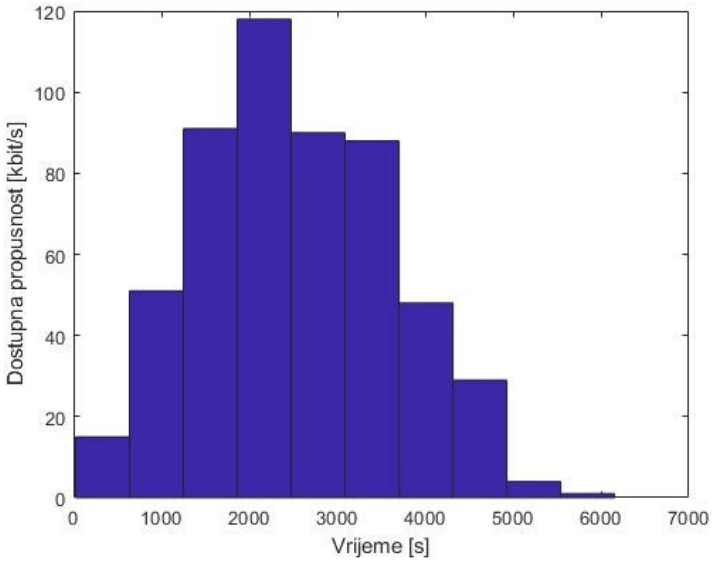


b)

Slika 6.5. Vremenski prikaz a) 3G mrežnog ispitnog zapisa Autobus-3; b) umjetno generiranog mrežnog ispitnog zapisa s parametrima m=0.983 i ω=3 782 106

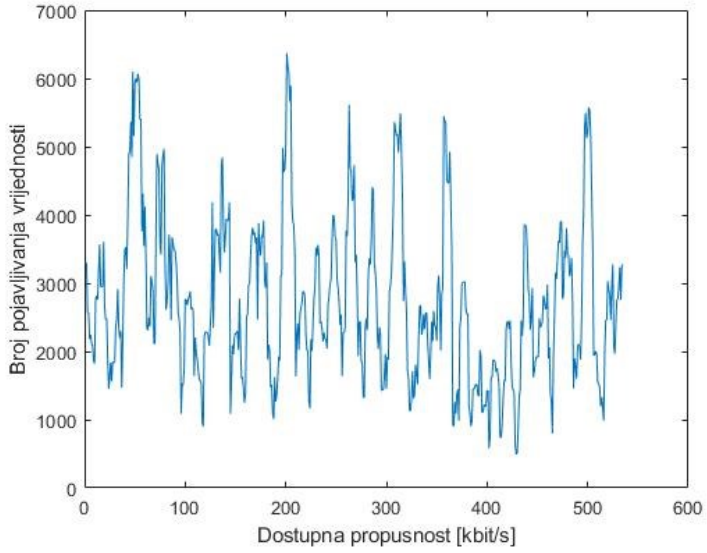


a)

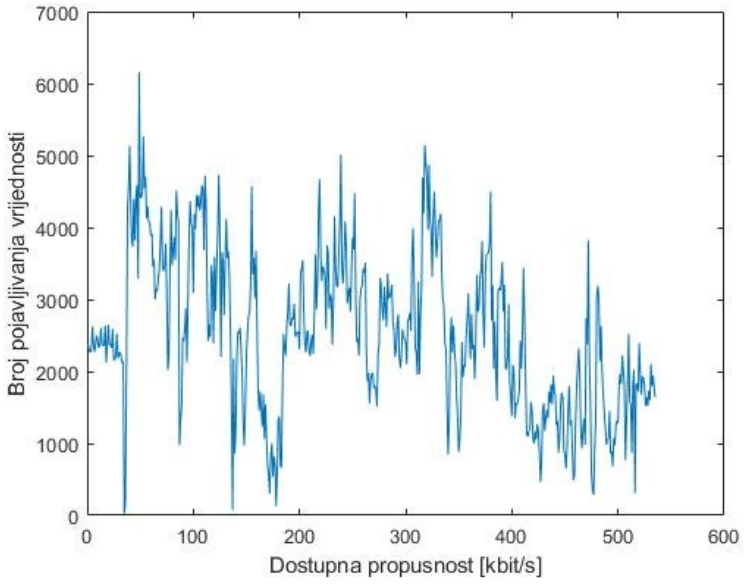


b)

Slika 6.6. a) Histogram 3G mrežnog ispitnog zapisa Autobus-5; b) histogram umjetno generiranog mrežnog ispitnog zapisa s parametrima m=1.310 i ω=7.597.10^6;



a)



b)

Slika 6.7. Vremenski prikaz a) 3G mrežnog ispitnog zapisa Autobus-5; b) umjetno generiranog mrežnog ispitnog zapisa s parametrima m=1.310 i ω=7.597.10^6

Stoga je u svrhu analize ponašanja algoritama za prilagodljivo videostrujanje važno koristiti veći broj umjetno generiranih mrežnih ispitnih zapisa s istim parametrima, a rezultate kao što su početno kašnjenje, prosječna razina kvalitete i broj prekida u reprodukciji videosignala treba izračunati kao prosječne vrijednosti za korištene mrežne ispitne zapise.

Budući da svako pokretanje programa za stvaranje umjetno generiranog mrežnog ispitnog zapisa stvara različite vremenske nizove slučajnih brojeva, čak i za iste parametre m i ω Nakagami

raspodjele vjerojatnosti, izvedene su simulacije umjetno generiranih mrežnih ispitnih zapisa tako da je za svaki skup parametara generirano 100 mrežnih ispitnih zapisa. Izlazni podaci dobiveni su kao prosjek postignutih rezultata za ovih 100 umjetno generiranih mrežnih ispitnih zapisa.

Rezultati simulacije videostrujanja korištenjem LIU algoritma za prilagodljivo videostrujanje prikazani su u tablicama 6.3. do 6.6. za odabrane 3G mrežne ispitne zapise, a u tablicama 6.7. do 6.9. za odabrane 4G mrežne ispitne zapise. Simulacija je izvršena za sve mrežne ispitne zapise iz tablica 6.1. i 6.2., ali rezultati su prikazani samo za odabranih 10 mrežnih ispitnih zapisa za 3G i 10 za 4G mrežu. Odabrani mrežni ispitni zapisi za koje je prikazana analiza u tablicama 6.3. do 6.9. dobro predstavljaju različite uvjete u kojima su mjereni (autobus, tramvaj, automobil itd.), kao i širok raspon parametara Nakagami raspodjele. Razlike analiziranih parametara za izmjerene i umjetno generirane mrežne ispitne zapise prikazani su kako bi se pokazala uspješnost umjetno generiranih mrežnih ispitnih zapisa u oponašaju realnih uvjeta u mreži.

Rezultati simulacije za 3G mrežu pokazuju da su razlike u rezultatima za umjetno generirane i izmjerene (stvarne) mrežne ispitne zapise ispod 10% u slučajevima kada je parametar *m* Nakagami raspodjele veći od 0,7 (ovaj zaključak odnosi se na sve mrežne ispitne zapise iz tablice 6.1.). Za mrežne ispitne zapise s m <0,7 odstupanja rezultata simulacije za umjetno generirane mrežne ispitne zapise u odnosu na rezultate za izmjerene mrežne ispitne zapise su značajno veća i dostižu 58% za srednju vrijednost odabrane prijenosne brzine za drugi mrežni ispitni zapis u tablici 6.6. koji ima $m = 0{,}249$.

Razlike za 4G mrežu su uglavnom ispod 10%, osim rezultata simulacije za mrežni ispitni zapis Pješak-4, gdje je prosječna procijenjena propusnost za umjetno generirani mrežni ispitni zapis 16,9 % niža nego za izmjereni mrežni ispitni zapis, a srednja vrijednost odabrane prijenosne brzine 21,15 % niža nego za izmjereni mrežni ispitni zapis. Parametar *m* za mrežni ispitni zapis Pješak-4 manji je od 0,5, što može biti uzrok razlika u rezultatima. Međutim, za ostale mrežne ispitne zapise 4G mreže s $m < 0{,}5$ odstupanja su znatno niži.

Može se zaključiti da mrežni ispitni zapisi umjetno generirani prema predloženom modelu dobro oponašaju mrežne ispitne zapise izmjerene u 3G i 4G mrežama kada se raspodjela vrijednosti propusnosti može prikazati Nakagami raspodjelom vjerojatnosti s parametrom $m > 0{,}7$. Iako su rezultati simulacije pokazali da za 4G mrežu umjetno generirani mrežni ispitni zapisi s $m < 7$ također postižu dobre rezultate kada se koriste u okviru za strujanje videosignala, potrebno je u budućnosti istražiti druge raspodjele koje su možda prikladnije od Nakagami raspodjele za određene izmjerene mrežne ispitne zapise. S obzirom na to da Nakagami raspodjela nije definirana za $m < 0{,}5$, u tim bi se slučajevima mogla koristiti Gama raspodjela.

Tablica 6.3. Rezultati simulacije za 3G mrežne ispitne zapise (autobus)

Ispitni zapis		**Prosječna razina kvalitete**	**Srednja procijenjena propusnost [kbit/s]**	**Srednja odabrana prijenosna brzina [kbit/s]**	**Broj prebacivanja razina kvalitete**	**Srednja dubina prebacivanja razina kvalitete**
Autobus-1	Izmjereni ispitni zapis	14.50	2882.28	2016.31	99.00	1.07
	Generirani ispitni zapis	14.29	2646.07	1933.14	98.39	1.11
	Razlika	0.22	236.21	83.17	0.61	-0.04
	Postotna razlika	1.48 %	8.20 %	4.13 %	0.62 %	-3.55 %
Autobus-2	Izmjereni ispitni zapis	14.29	2114.53	1547.48	99.00	1.07
	Generirani ispitni zapis	11.91	1741.00	1169.96	98.85	1.17
	Razlika	1.38	373.53	377.53	0.15	-0.10
	Postotna razlika	10.40 %	17.67 %	24.40 %	0.15 %	-9.44 %
Autobus-3	Izmjereni ispitni zapis	12.25	1650.16	1209.51	99.00	1.06
	Generirani ispitni zapis	12.78	1813.06	1362.71	99.00	1.11
	Razlika	-0.53	-162.90	-153.20	0.00	-0.05
	Postotna razlika	-4.35 %	-9.87 %	-12.67 %	0.00 %	-4.30 %

Tablica 6.4. Rezultati simulacije za 3G mrežne ispitne zapise (tramvaj)

Ispitni zapis		**Prosječna razina kvalitete**	**Srednja procijenjena propusnost [kbit/s]**	**Srednja odabrana prijenosna brzina [kbit/s]**	**Broj prebacivanja razina kvalitete**	**Srednja dubina prebacivanja razina kvalitete**
Tramvaj-1	Izmjereni ispitni zapis	8.74	755.45	513.17	99.00	1.07
	Generirani ispitni zapis	9.34	772.84	585.46	99.00	1.12
	Razlika	-0.59	-17.39	-72.29	0.00	-0.05
	Postotna razlika	-6.79 %	-2.30 %	-14.09 %	0.00 %	-4.47 %
Tramvaj-2	Izmjereni ispitni zapis	9.53	842.45	608.05	99.00	1.13
	Generirani ispitni zapis	9.50	815.19	615.65	99.00	1.12
	Razlika	0.04	27.26	-7.60	0.00	0.01
	Postotna razlika	0.38 %	3.24 %	-1.25 %	0.00 %	0.75 %

Tablica 6.5. Rezultati simulacije za 3G mrežne ispitne zapise (vlak)

Ispitni zapis		**Prosječna razina kvalitete**	**Srednja procijenjena propusnost [kbit/s]**	**Srednja odabrana prijenosna brzina [kbit/s]**	**Broj prebacivanja razina kvalitete**	**Srednja dubina prebacivanja razina kvalitete**
Vlak-1	Izmjereni ispitni zapis	12.28	1554.09	1189.95	99.00	1.12
	Generirani ispitni zapis	11.85	1498.14	1100.80	99.00	1.12
	Razlika	0.42	55.95	89.15	0.00	0.00
	Postotna razlika	3.45 %	3.60 %	7.49 %	0.00 %	-0.21 %
Vlak-2	Izmjereni ispitni zapis	13.43	2044.67	1600.18	99.00	1.07
	Generirani ispitni zapis	11.94	1603.80	1150.48	98.97	1.14
	Razlika	1.48	440.87	449.70	0.03	-0.07
	Postotna razlika	11.05 %	21.56 %	28.10 %	0.03 %	-6.56 %

Tablica 6.6. Rezultati simulacije za 3G mrežne ispitne zapise (automobil)

Ispitni zapis		**Prosječna razina kvalitete**	**Srednja procijenjena propusnost [kbit/s]**	**Srednja odabrana prijenosna brzina [kbit/s]**	**Broj prebacivanja razina kvalitete**	**Srednja dubina prebacivanja razina kvalitete**
Automobil-1	Izmjereni ispitni zapis	13.02	1805.73	1410.07	99.00	1.08
	Generirani ispitni zapis	8.70	964.37	579.08	98.72	1.22
	Razlika	4.32	841.36	830.98	0.28	-0.14
	Postotna razlika	33.14 %	46.59 %	58.93 %	0.28 %	-13.22 %
Automobil-2	Izmjereni ispitni zapis	12.83	1913.05	1424.28	63.00	1.03
	Generirani ispitni zapis	12.64	1992.16	1403.30	63.00	1.10
	Razlika	0.19	-79.11	20.98	0.00	-0.06
	Postotna razlika	1.45 %	-4.14 %	1.47 %	0.00 %	-6.26 %
Automobil-3	Izmjereni ispitni zapis	13.11	2025.97	1531.20	64.00	1.08
	Generirani ispitni zapis	12.82	2125.98	1472.45	63.96	1.11
	Razlika	0.28	-100.01	58.75	0.04	-0.03
	Postotna razlika	2.16 %	-4.94 %	3.84 %	0.06 %	-2.56 %

Tablica 6.7. Rezultati simulacije za 4G mrežne ispitne zapise (autobus i tramvaj)

Ispitni zapis		**Prosječna razina kvalitete**	**Prosječna procijenjena propusnost [kbit/s]**	**Prosječna odabrana prijenosna brzina [kbit/s]**	**Broj prebacivanja razina kvalitete**	**Srednja dubina prebacivanja razina kvalitete**
Autobus-1	Izmjereni ispitni zapis	14.50	27829.65	20282.27	99.00	1.05
	Generirani ispitni zapis	14.62	28322.49	20755.15	98.56	1.09
	Razlika	-0.12	-492.84	-472.89	0.44	-0.04
	Postotna razlika	-0.81 %	-1.77 %	-2.33 %	0.44 %	-3.59 %
Autobus-2	Izmjereni ispitni zapis	15.47	32329.32	24355.70	90.00	1.07
	Generirani ispitni zapis	14.79	31455.64	21589.76	87.23	1.13
	Razlika	0.67	873.69	2765.93	2.77	-0.06
	Postotna razlika	4.36 %	2.70 %	11.36 %	3.08 %	-5.98 %
Tramvaj-2	Izmjereni ispitni zapis	12.01	17907.49	12560.00	99.00	1.14
	Generirani ispitni zapis	11.33	16190.70	10484.28	98.97	1.18
	Razlika	0.68	1716.79	2075.72	0.03	-0.04
	Postotna razlika	5.64 %	9.59 %	16.53 %	0.03 %	-3.67 %
Tramvaj-4	Izmjereni ispitni zapis	15.64	36720.06	25239.60	72.00	1.04
	Generirani ispitni zapis	15.56	37835.10	25012.51	64.66	1.11
	Razlika	0.08	-1115.04	227.09	7.34	-0.07
	Postotna razlika	0.53 %	-3.04 %	0.90 %	10.19 %	-6.93 %

Tablica 6.8. Rezultati simulacije za 4G mrežne ispitne zapise (vlak, bicikl i automobil)

Ispitni zapis		**Prosječna razina kvalitete**	**Prosječna procijenjena propusnost [kbit/s]**	**Prosječna odabrana prijenosna brzina [kbit/s]**	**Broj prebacivanja razina kvalitete**	**Srednja dubina prebacivanja razina kvalitete**
Vlak-1	Izmjereni ispitni zapis	13.55	22318.88	16795.74	84.00	1.08
	Generirani ispitni zapis	13.32	24836.27	16332.07	83.25	1.16
	Razlika	0.23	-2517.39	463.68	0.75	-0.08
	Postotna razlika	1.68 %	-11.28 %	2.76 %	0.89 %	-7.27 %
Bicikl-1	Izmjereni ispitni zapis	15.44	31740.85	24213.71	88.00	1.11
	Generirani ispitni zapis	15.06	32014.45	22773.45	85.68	1.11
	Razlika	0.39	-273.60	1440.27	2.32	0.00
	Postotna razlika	2.50 %	-0.86 %	5.95 %	2.64 %	0.39 %
Automobil-2	Izmjereni ispitni zapis	14.68	27326.90	20740.34	90.00	1.12
	Generirani ispitni zapis	14.74	30043.14	21279.02	91.68	1.12
	Razlika	-0.07	-2716.24	-538.68	-1.68	0.00
	Postotna razlika	-0.45 %	-9.94 %	-2.60 %	-1.87 %	0.27 %
Automobil-4	Izmjereni ispitni zapis	15.49	33160.23	24565.33	75.00	1.04
	Generirani ispitni zapis	15.64	37070.01	25418.86	69.22	1.09
	Razlika	-0.15	-3909.78	-853.53	5.78	-0.05
	Postotna razlika	-0.95 %	-11.79 %	-3.47 %	7.71 %	-5.17 %

Tablica 6.9. Rezultati simulacije za 4G mrežne ispitne zapise (pješak)

Ispitni zapis		Prosječna razina kvalitete	Prosječna procijenjena propusnost [kbit/s]	Prosječna odabrana prijenosna brzina [kbit/s]	Broj prebacivanja razina kvalitete	Srednja dubina prebacivanja razina kvalitete
Pješak-1	Izmjereni ispitni zapis	16.59	41668.79	29071.15	52.00	1.00
	Generirani ispitni zapis	16.00	41560.84	26919.00	54.83	1.08
	Razlika	0.59	107.95	2152.15	-2.83	-0.08
	Postotna razlika	3.56 %	0.26 %	7.40 %	-5.44 %	-7.68 %
Pješak-2	Izmjereni ispitni zapis	13.67	23120.79	17136.79	99.00	1.09
	Generirani ispitni zapis	12.62	19213.95	13511.68	98.94	1.15
	Razlika	1.06	3906.84	3625.11	0.06	-0.06
	Postotna razlika	7.2%	16.90%	21.15%	0.06%	-5.28%

6.4. Rezultati mjerenja utjecaja parametara mreže i reprezentacija videosignala na SSIM

Okvir za analizu i optimizaciju parametara algoritama za videostrujanje prilagodljivo mrežnim uvjetima zasnovano na MPEG DASH normi primijenjen je za ispitivanje utjecaja mrežnih parametara, iskazanih preko Nakagami parametra m i srednje vrijednosti dostupne propusnosti, na parametre kvalitete korisničkog iskustva: početno kašnjenje, prosječnu razinu kvalitete videosignala nakon videostrujanja (prosjek razina kvalitete preuzetih videosegmenata), prosječnu odabranu prijenosnu brzinu (prosjek odabranih prijenosnih brzina za sve preuzete videosegmente), broj prebacivanja razina kvalitete, prosječnu dubinu prebacivanja razina kvalitete (prosjek razlika između razina kvalitete za sukcesivne videosegmente) te broj i trajanje prekida u reprodukciji videosignala.

Ispitivanja su izvršena za Lederer segmentaciju videosignala BBB i segmentaciju prema metodi predloženoj u ovom doktorskom radu pomoću LIU algoritma za prilagodljivo videostrujanje. Srednja vrijednost dostupne propusnosti, Mv korištena je za izračun Nakagami parametra ω korištenjem izraza (6-14).

$$\omega = \left(\frac{\Gamma(m)}{\Gamma(m+\frac{1}{2})}\right)^2 Mv^2 \cdot m \qquad (6\text{-}14)$$

S obzirom da se mrežni ispitni zapisi mijenjaju svakim pokretanjem programa, postoje razlike u srednjih vrijednostima dostupne propusnosti za iste parametre m i ω, svi rezultati mjerenja dani su kao srednja vrijednost za 100 umjetno generiranih mrežnih ispitnih zapisa. Simulacija je napravljena za vrijednosti Mv od 700 do 2800 kbit/s, za vrijednosti parametra m=0,7 (rezultati su prikazani u tablici 6.10.), m=1 (tablica 6.11) i m=1,3 (tablica 6.12). U tom rasponu vrijednosti dostupne propusnosti i parametra m, LIU algoritam je uspio prilagoditi videostrujanje tako da se ne pojave zastoji u reprodukciji videosignala. Kako bi se ispitali rezultati i u uvjetima kada se pojave zastoji, u drugom dijelu eksperimenta u dio generiranog mrežnog zapisa zamijenjen je dijelom s konstantnom propusnošću od 10 kbit/s. Rezultati za ovaj dio ispitivanja su dani u tablicama 6.13 do 6.15.

Iz tablica 6.10. do 6.15. može se vidjeti da se povećanjem parametra m, smanjuju vrijednosti prosječne procijenjene propusnosti za određeni ω. S obzirom da vrijednosti početnog kašnjenja ovise o vrijednostima prosječne procijenjene propusnosti, početno kašnjenje za određeni ω se povećava kako se povećava m.

Prosječna propusnost odabrane razine i SSIM povećavaju se kako se povećavaju parametri m i ω. U slučaju kada nisu dodatni prekidi u reprodukciji videosignala, broj prebacivanja razina kvalitete se ne mijenja, ali se u većini slučajeva dubina prebacivanja razina kvalitete povećava kako se povećava m.

Iz tablica 6.13. do 6.15. može se vidjeti da duljina i trajanje zastoja ne ovise o parametrima m i ω. Broj prebacivanja razina kvalitete povećava se u ovisnosti o ω, ali ne ovisi o m. Dubina prebacivanja najveća je za m=1,3 za ω određen za srednju vrijednost dostupne propusnosti koja je manja ili jednaka 1900 kbit/s. Iz priloženih tablica može se vidjeti da predložena segmentacija ostvaruje veću prosječnu prijenosnu brzinu odabrane razine kvalitete od 2,9 do 9,2 % u ovisnosti o korištenoj srednjoj vrijednosti dostupne propusnosti, Mv, Nakagami parametru m i postoje li zastoji u reprodukciji videosignala. Povećanjem vrijednosti m i Mv, povećava se i razlika u prosječnoj prijenosnoj brzini odabrane razine kvalitete. Također, veće vrijednosti razlike prosječne prijenosne brzine odabrane razine kvalitete opažaju se u ispitnim slučajevima kada postoje zastoji u reprodukciji videosignala.

Tablica 6.10. za m=0,7 bez dodanih prekida u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]		Prosječna procijenjena propusnost [kbit/s]	Prosječna propusnost odabrane razine [kbit/s]	SSIM	Broj prebacivanja razina kvalitete	Dubina prebacivanja razina kvalitete	Početno kašnjenje [s]
700	Lederer segmentacija	907,7601	680,3956	0,9146	99	1,1268	0,3100
	Predložena segmentacija	893,9758	705,4963	0,9149	99	1,0932	0,3350
	Razlika	13,7842	-25,1006	-0,0003	0	0,0336	-0,0250
	Postotna razlika	1,5185	-3,6891	-0,0319	0	2,9824	-8,0645
1100	Lederer segmentacija	1173,7829	891,3458	0,9208	99	1,1060	0,2050
	Predložena segmentacija	1162,6414	918,2819	0,9211	99	1,0765	0,2250
	Razlika	11,1415	-26,9361	-0,0003	0	0,0294	-0,0200
	Postotna razlika	0,9492	-3,0220	-0,0295	0	2,6609	-9,7561
1500	Lederer segmentacija	1384,9470	1057,2196	0,9246	99	1,0972	0,1550
	Predložena segmentacija	1383,0305	1091,2395	0,9250	99	1,0688	0,1700
	Razlika	1,9165	-34,0198	-0,0003	0	0,0284	-0,0150
	Postotna razlika	0,1384	-3,2179	-0,0358	0	2,5881	-9,6774
1900	Lederer segmentacija	1517,1902	1130,0987	0,9255	99	1,1257	0,1900
	Predložena segmentacija	1481,2740	1169,4025	0,9257	99	1,0923	0,2050
	Razlika	35,9162	-39,3037	-0,0002	0	0,0333	-0,0150
	Postotna razlika	2,3673	-3,4779	-0,0213	0	2,9591	-7,8947
2400	Lederer segmentacija	1721,2350	1298,1548	0,9288	99	1,1004	0,1400
	Predložena segmentacija	1723,4881	1362,1101	0,9294	99	1,0779	0,1550
	Razlika	-2,2531	-63,9554	-0,0006	1	0,0225	-0,0150
	Postotna razlika	-0,1309	-4,9266	-0,0663	1	2,0490	-10,7143
2800	Lederer segmentacija	1907,5309	1437,2572	0,9311	99	1,0895	0,1150
	Predložena segmentacija	1912,9954	1510,9341	0,9319	99	1,0649	0,1250
	Razlika	-5,4646	-73,6769	-0,0007	0	0,0246	-0,0100
	Postotna razlika	-0,2865	-5,1262	-0,0790	0	2,2577	-8,6957

Tablica 6.11. za m=1 bez dodanih prekida u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]		Prosječna procijenjena propusnost [kbit/s]	Prosječna propusnost odabrane razine [kbit/s]	SSIM	Broj prebacivanja razina kvalitete	Dubina prebacivanja razina kvalitete	Početno kašnjenje [s]
700	Lederer segmentacija	863,3242	652,5679	0,9138	99	1,1279	0,3250
	Predložena segmentacija	846,4219	671,4227	0,9139	99	1,0973	0,3550
	Razlika	16,9023	-18,8548	-0,0001	0	0,0305	-0,0300
	Postotna razlika	1,9578	-2,8893	-0,0121	0	2,7070	-9,2308
1100	Lederer segmentacija	1124,1099	854,0367	0,9199	99	1,1034	0,2150
	Predložena segmentacija	1118,1643	886,5014	0,9204	99	1,0740	0,2350
	Razlika	5,9455	-32,4646	-0,0005	0	0,0295	-0,0200
	Postotna razlika	0,5289	-3,8013	-0,0501	0	2,6694	-9,3023
1500	Lederer segmentacija	1309,7628	997,9162	0,9235	99	1,0933	0,1650
	Predložena segmentacija	1314,8465	1035,1727	0,9239	99	1,0656	0,1800
	Razlika	-5,0837	-37,2565	-0,0004	0	0,0277	-0,0150
	Postotna razlika	-0,3881	-3,7334	-0,0419	0	2,5355	-9,0909
1900	Lederer segmentacija	1447,2037	1071,0236	0,9243	99	1,1286	0,1950
	Predložena segmentacija	1401,1148	1104,1945	0,9245	99	1,0893	0,2150
	Razlika	46,0888	-33,1709	-0,0002	0	0,0393	-0,0200
	Postotna razlika	3,1847	-3,0971	-0,0268	0	3,4822	-10,2564
2400	Lederer segmentacija	1654,1540	1244,7705	0,9279	99	1,1054	0,1450
	Predložena segmentacija	1613,2087	1273,5861	0,9280	99	1,0761	0,1600
	Razlika	40,9452	-28,8156	-0,0001	0	0,0292	-0,0150
	Postotna razlika	2,4753	-2,3149	-0,0073	0	2,6445	-10,3448
2800	Lederer segmentacija	1817,7729	1365,6145	0,9300	99	1,0946	0,1200
	Predložena segmentacija	1815,5417	1432,2276	0,9307	99	1,0671	0,1300
	Razlika	2,2311	-66,6131	-0,0007	0	0,0275	-0,0100
	Postotna razlika	0,1227	-4,8779	-0,0744	0	2,5126	-8,3333

Tablica 6.12. za m=1,3 bez dodanih prekida u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]		Prosječna procijenjena propusnost [kbit/s]	Prosječna propusnost odabrane razine [kbit/s]	SSIM	Broj prebacivanja razina kvalitete	Dubina prebacivanja razina kvalitete	Početno kašnjenje [s]
700	Lederer segmentacija	844,0414	634,9210	0,9132	99	1,1292	0,3300
	Predložena segmentacija	827,5672	652,3451	0,9131	99	1,0974	0,3600
	Razlika	16,4741	-17,4240	0,0001	0	0,0317	-0,0300
	Postotna razlika	1,9518	-2,7443	0,0067	0	2,8111	-9,0909
1100	Lederer segmentacija	1081,1559	821,9906	0,9191	99	1,1066	0,2200
	Predložena segmentacija	1059,7726	838,6413	0,9191	99	1,0785	0,2450
	Razlika	21,3833	-16,6506	0,0000	0	0,0281	-0,0250
	Postotna razlika	1,9778	-2,0256	-0,0022	0	2,5391	-11,3636
1500	Lederer segmentacija	1296,1855	984,8189	0,9231	99	1,0953	0,1650
	Predložena segmentacija	1292,7408	1022,3799	0,9236	99	1,0656	0,1850
	Razlika	3,4447	-37,5610	-0,0005	0	0,0296	-0,0200
	Postotna razlika	0,2658	-3,8140	-0,0533	0	2,7063	-12,1212
1900	Lederer segmentacija	1397,9150	1037,8669	0,9236	99	1,1286	0,2000
	Predložena segmentacija	1356,7822	1067,9764	0,9237	99	1,0945	0,2200
	Razlika	41,1327	-30,1096	-0,0001	0	0,0341	-0,0200
	Postotna razlika	2,9424	-2,9011	-0,0097	0	3,0211	-10,0000
2400	Lederer segmentacija	1606,5272	1212,2497	0,9273	99	1,1041	0,1500
	Predložena segmentacija	1587,5164	1255,2051	0,9277	99	1,0781	0,1650
	Razlika	19,0108	-42,9554	-0,0004	0	0,0261	-0,0150
	Postotna razlika	1,1833	-3,5434	-0,0422	0	2,3620	-10,0000
2800	Lederer segmentacija	1756,2873	1322,4437	0,9294	99	1,0953	0,1250
	Predložena segmentacija	1750,4274	1374,9632	0,9298	99	1,0639	0,1350
	Razlika	5,8599	-52,5195	-0,0004	0	0,0314	-0,0100
	Postotna razlika	0,3337	-3,9714	-0,0484	0	2,8646	-8,0000

Analizom SSIM vrijednosti izračunatih za obje segmentacije, može se zaključiti da predložena segmentacija ostvaruje veću kvalitetu videosignala neovisno o uvjetima u mreži ali se također povećanjem vrijednosti *m* i *Mv* povećavaju i postotne razlike između ostvarenih SSIM vrijednosti. Kao i u slučaju prosječne prijenosne brzine odabrane razine kvalitete, veće razlike SSIM vrijednosti u korist predložene segmentacije mogu se vidjeti u ispitnim slučajevima kada postoje zastoji u reprodukciji videosignala.

U slučaju kada nema zastoja u reprodukciji videosignala, promjene u dostupnoj propusnosti nisu imale utjecaj na broj prebacivanja razina kvalitete. Pojavljivanjem zastoja u reprodukciji videosignala, broj prebacivanja razina kvalitete ali i dubina prebacivanja razina kvalitete se mijenjaju i u većini slučajeva predložena segmentacija ima manji broj prebacivanja razina kvalitete i manju dubinu prebacivanja razine kvalitete što povoljno utječe na kvalitetu korisničkog iskustva.

Jedini parametar koji je za predloženu segmentaciju lošiji nego za Lederer segmentaciju je početno kašnjenje koje je za predloženu segmentaciju veće od 7,9% do 12%. Razlog tome su manje vrijednosti prosječne procijenjene propusnosti određene iz umjetno generiranih mrežnih ispitnih zapisa. Upravo zbog promjena u početnom kašnjenju u voisnosti o mrežnim ispitnim zapisima, za potrebe ispitivanja optimalnog broja reprezentacija koja slijede, vrijednosti početnog kašnjenja postavljene su na način da budu jednake za sve prolaze kada se korite ispti parametri Nakagami raspodjele vjerojatnosti.

Predložena segmentacija ostvaruje manje duljine zastoja (od 3% do 37%) te manji broj zastoja (od 20% do 84%). Kako zastoji tijekom reprodukcije videosignala imaju puno značajniji utjecaj na smanjenje QoE nego početno kašnjenje, [49], povećanje početnog kašnjenja do 12% bit će nadmašeno smanjenjem zastoja tijekom reprodukcije videosignala u ukupnom utjecaju na QoE.

Tablica 6.13. za m=0.7 s dodanim prekidima u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]		Prosječna procijenjena propusnost [kbit/s]	Prosječna propusnost odabrane razine [kbit/s]	SSIM	Duljina zastoja	Broj zastoja	Broj prebacivanja razina kvalitete	Dubina prebacivanja razina kvalitete	Početno kašnjenje [s]
700	Lederer segmentacija	814,5820	583,1267	0,9070	195,5003	4,2300	90,8200	1,1720	0,3100
	Predložena segmentacija	810,7919	606,5351	0,9072	187,2664	3,4000	90,3200	1,1462	0,3350
	Razlika	3,7901	-23,4084	-0,0002	8,2340	0,8300	0,5000	0,0258	-0,0250
	Postotna razlika	0,4653	-4,0143	-0,0257	4,2117	19,6217	0,5505	2,1977	-8,0645
1100	Lederer segmentacija	1067,0505	751,9259	0,9122	214,5012	4,8500	91,7600	1,1637	0,2050
	Predložena segmentacija	1085,3617	802,3610	0,9134	176,4603	1,7500	91,5300	1,1356	0,2250
	Razlika	-18,3113	-50,4351	-0,0012	38,0409	3,1000	0,2300	0,0282	-0,0200
	Postotna razlika	-1,7161	-6,7075	-0,1313	17,7346	63,9175	0,2507	2,4222	-9,7561
1500	Lederer segmentacija	1269,7711	882,9833	0,9154	212,1279	4,5200	92,3800	1,1571	0,1550
	Predložena segmentacija	1289,2564	932,0238	0,9168	176,8005	1,0000	92,6400	1,1296	0,1700
	Razlika	-19,4853	-49,0405	-0,0014	35,3275	3,5200	-0,2600	0,0274	-0,0150
	Postotna razlika	-1,5345	-5,5540	-0,1532	16,6538	77,8761	-0,2814	2,3721	-9,6774
1900	Lederer segmentacija	1364,8872	933,1484	0,9161	226,6106	4,6000	92,6400	1,1798	0,1900
	Predložena segmentacija	1383,1582	1009,0708	0,9173	205,0387	2,8100	92,1100	1,1479	0,2050
	Razlika	-18,2709	-75,9223	-0,0012	21,5719	1,7900	0,5300	0,0319	-0,0150
	Postotna razlika	-1,3386	-8,1361	-0,1291	9,5194	38,9130	0,5721	2,7010	-7,8947
2400	Lederer segmentacija	1606,4015	1079,7080	0,9193	218,6085	3,8200	93,5800	1,1748	0,1400
	Predložena segmentacija	1600,9791	1158,0470	0,9210	195,9997	1,0000	93,9100	1,1454	0,1550
	Razlika	5,4223	-78,3390	-0,0017	22,6088	2,8200	-0,3300	0,0294	-0,0150
	Postotna razlika	0,3375	-7,2556	-0,1901	10,3421	73,8220	-0,3526	2,5023	-10,7143
2800	Lederer segmentacija	1764,2308	1195,0256	0,9217	221,7979	3,2500	94,3500	1,1653	0,1150
	Predložena segmentacija	1796,2983	1294,1049	0,9233	197,1158	1,0000	94,3800	1,1363	0,1250
	Razlika	-32,0675	-99,0793	-0,0017	24,6821	2,2500	-0,0300	0,0291	-0,0100
	Postotna razlika	-1,8176	-8,2910	-0,1800	11,1282	69,2308	-0,0318	2,4953	-8,6957

Tablica 6.14. za m=1 s dodanim prekidima u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]		Prosječna procijenjen propusnost [kbit/s]	Prosječna propusnost odabrane razine [kbit/s]	SSIM	Duljina zastoja	Broj zastoja	Broj prebacivanja razina kvalitete	Dubina prebacivanja razina kvalitete	Početno kašnjenj [s]
700	Lederer segmentacija	793,9640	564,2869	0,9063	229,3257	6,0300	90,9300	1,1751	0,3250
	Predložena segmentacija	784,1653	586,7694	0,9066	165,0702	2,6400	90,1000	1,1433	0,3550
	Razlika	9,7987	-22,4825	-0,0003	64,2555	3,3900	0,8300	0,0319	-0,0300
	Postotna razlika	1,2342	-3,9842	-0,0362	28,0193	56,2189	0,9128	2,7121	-9,2308
1100	Lederer segmentacija	1008,5397	718,2462	0,9115	208,3296	4,2200	91,8700	1,1640	0,2150
	Predložena segmentacija	1009,6493	751,0692	0,9123	181,6655	1,6900	91,6200	1,1347	0,2350
	Razlika	-1,1096	-32,8230	-0,0009	26,6641	2,5300	0,2500	0,0293	-0,0200
	Postotna razlika	-0,1100	-4,5699	-0,0946	12,7990	59,9526	0,2721	2,5145	-9,3023
1500	Lederer segmentacija	1203,0951	844,9059	0,9148	181,4635	2,5900	92,5300	1,1535	0,1650
	Predložena segmentacija	1235,4161	910,3148	0,9162	172,6203	1,0000	92,2900	1,1235	0,1800
	Razlika	-32,3210	-65,4089	-0,0015	8,8432	1,5900	0,2400	0,0300	-0,0150
	Postotna razlika	-2,6865	-7,7416	-0,1628	4,8733	61,3900	0,2594	2,5975	-9,0909
1900	Lederer segmentacija	1313,2042	891,5737	0,9152	195,5238	3,1900	92,4400	1,1846	0,1950
	Predložena segmentacija	1323,8015	967,5893	0,9167	166,7411	1,0000	92,1900	1,1500	0,2150
	Razlika	-10,5973	-76,0156	-0,0015	28,7827	2,1900	0,2500	0,0347	-0,0200
	Postotna razlika	-0,8070	-8,5260	-0,1667	14,7208	68,6520	0,2704	2,9261	-10,2564
2400	Lederer segmentacija	1516,7297	1038,2071	0,9186	225,9086	3,9800	93,2200	1,1758	0,1450
	Predložena segmentacija	1518,5852	1103,1308	0,9200	195,0359	1,0000	93,4900	1,1402	0,1600
	Razlika	-1,8555	-64,9237	-0,0015	30,8728	2,9800	-0,2700	0,0356	-0,0150
	Postotna razlika	-0,1223	-6,2534	-0,1579	13,6660	74,8744	-0,2896	3,0298	-10,3448
2800	Lederer segmentacija	1686,5920	1152,3072	0,9209	185,3908	1,6300	93,9900	1,1630	0,1200
	Predložena segmentacija	1678,4575	1207,8785	0,9218	179,1624	1,0000	93,9300	1,1296	0,1300
	Razlika	8,1345	-55,5714	-0,0009	6,2283	0,6300	0,0600	0,0334	-0,0100
	Postotna razlika	0,4823	-4,8226	-0,0979	3,3596	38,6503	0,0638	2,8736	-8,3333

Tablica 6.15. za m=1,3 s dodanim prekidima u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]		Prosječna procijenjena propusnost [kbit/s]	Prosječna propusnost odabrane razine [kbit/s]	SSIM	Duljina zastoja	Broj zastoja	Broj prebacivanja razina kvalitete	Dubina prebacivanja razina kvalitete	Početno kašnjenje [s]
700	Lederer segmentacija	766,5941	546,6018	0,9056	223,3140	6,2800	90,3400	1,1665	0,3300
	Predložena segmentacija	763,1032	568,4003	0,9063	141,0394	1,0000	90,5200	1,1486	0,3600
	Razlika	3,4909	-21,7985	-0,0006	82,2746	5,2800	-0,1800	0,0179	-0,0300
	Postotna razlika	0,4554	-3,9880	-0,0701	36,8426	84,0764	-0,1992	1,5335	-9,0909
1100	Lederer segmentacija	994,3278	707,2455	0,9112	208,1582	3,9800	91,8900	1,1655	0,2200
	Predložena segmentacija	989,8529	738,0918	0,9121	169,9462	1,0000	91,7800	1,1331	0,2450
	Razlika	4,4750	-30,8463	-0,0008	38,2120	2,9800	0,1100	0,0323	-0,0250
	Postotna razlika	0,4500	-4,3615	-0,0931	18,3572	74,8744	0,1197	2,7745	-11,3636
1500	Lederer segmentacija	1174,8806	832,4946	0,9143	225,4301	5,1800	92,1200	1,1578	0,1650
	Predložena segmentacija	1195,8625	881,1628	0,9157	207,7719	2,1600	92,4200	1,1306	0,1850
	Razlika	-20,9820	-48,6682	-0,0014	17,6583	3,0200	-0,3000	0,0273	-0,0200
	Postotna razlika	-1,7859	-5,8461	-0,1504	7,8331	58,3012	-0,3257	2,3541	-12,1212
1900	Lederer segmentacija	1292,4708	886,6108	0,9151	226,1824	4,7600	92,3700	1,1846	0,2000
	Predložena segmentacija	1291,5768	939,0792	0,9161	195,6824	2,1700	92,3400	1,1458	0,2200
	Razlika	0,8940	-52,4684	-0,0010	30,5000	2,5900	0,0300	0,0388	-0,0200
	Postotna razlika	0,0692	-5,9179	-0,1056	13,4847	54,4118	0,0325	3,2773	-10,0000
2400	Lederer segmentacija	1472,4974	1008,4543	0,9179	225,7347	4,4200	93,0500	1,1697	0,1500
	Predložena segmentacija	1494,0355	1085,2462	0,9195	178,9488	1,0000	93,1600	1,1430	0,1650
	Razlika	-21,5380	-76,7919	-0,0016	46,7860	3,4200	-0,1100	0,0267	-0,0150
	Postotna razlika	-1,4627	-7,6148	-0,1747	20,7261	77,3756	-0,1182	2,2839	-10,0000
2800	Lederer segmentacija	1628,6611	1106,4104	0,9202	226,2393	3,4500	94,0400	1,1594	0,1250
	Predložena segmentacija	1672,6968	1207,9902	0,9221	198,0199	1,0000	94,3900	1,1362	0,1350
	Razlika	-44,0358	-101,5798	-0,0018	28,2194	2,4500	-0,3500	0,0232	-0,0100
	Postotna razlika	-2,7038	-9,1810	-0,2001	12,4732	71,0145	-0,3722	2,0026	-8,0000

U drugom dijelu istraživanja ispitan je utjecaj razlike MOS vrijednosti korištene prilikom određivanja broja razina kvalitete na parametre kvalitete korisničkog iskustva i SSIM vrijednosti. Za potrebe ispitivanja korištena su dva videosignala BBB i EM da bi se ispitao utjecaj korištenja različitog broja reprezentacija na videosignale s različitim SITI-jem. BBB ima SITI 229.88, a EM ima SITI 1357.14. Rezultati ispitivanja za videosignal BBB prikazani su tablicama 6.16. do 6.21, a rezultati za videosignal EM prikazani su tablicama u prilozima P.12. do P.17.

U ispitivanjima u kojima nema zastoja u reprodukciji videosignala, povećanjem razlike MOS vrijednosti korištene prilikom određivanja broja razina kvalitete, povećavaju se i prosječna prijenosna brzina odabrane razine kvalitete i SSIM vrijednosti za oba videosignala, dok se dubina prebacivanja razina kvalitete smanjuje, Usporedbom BBB i EM videosignala može se vidjeti da BBB ostvaruje veće vrijednosti SSIM-a i manje vrijednosti početnog kašnjenja što je i očekivano jer je BBB jednostavniji za kodiranje i ima videosegmente manje veličine. Također, promjena SSIM vrijednosti u ovisnosti o razlici MOS vrijednosti značajnija je kod EM videosignala.

U slučaju kada postoje zastoji u reprodukciji videosignala, SSIM vrijednosti i prosječna prijenosna brzina odabrane razine kvalitete povećavaju se povećanjem razlike MOS vrijednosti za određeni ω, ali se smanjuju povećanjem parametra m. Duljina zastoja ne ovisi o parametru m, ali videosignal EM koji ima veći SITI, ima i značajno dulje trajanje zastoja u reprodukciji videosignala.

Dubina prebacivanja razina kvalitete smanjuje se kako se povećava razlika MOS vrijednosti. Ovime je potvrđeno da za BBB videosignal, razlika MOS vrijednosti 2 predstavlja kompromis između broja i dubine prebacivanja razina kvalitete, broja i duljine trajanja zastoja u reprodukciji videosignala i SSIM vrijednosti. Isto vrijedi i za EM videosignal, no s obzirom da se kod EM videosignala SSIM vrijednosti značajnije povećavaju povećanjem razlike MOS vrijednosti i da su duljina i broj zastoja manji kada se koristi razlika MOS vrijednosti 3 u odnosu kada se koristi razlika MOS vrijednosti 2, preporučuje se za videosignale s višim vrijednostima SITI-ja koristiti razliku MOS vrijednosti 3.

Tablica 6.16. BBB za m=0,7 bez dodanih prekida u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]	**Razlika MOS vrijedosti**	**Prosječna procijenjena propusnost [kbit/s]**	**Prosječna propusnost odabrane razine [kbit/s]**	**SSIM**	**Broj prebacivanja razina kvalitete**	**Dubina prebacivanja razina kvalitete**	**Početno kašnjenje [s]**
700	1	911,2681	638,4611	0,9122	99	1,1389	0,3350
	2	893,9758	705,4963	0,9149	99	1,0932	0,3350
	3	895,5176	743,4644	0,9159	99	1,0688	0,3350
1100	1	1180,3309	834,2333	0,9179	99	1,1115	0,2250
	2	1162,6414	918,2819	0,9211	99	1,0765	0,2250
	3	1163,5944	961,4072	0,9220	99	1,0544	0,2250
1500	1	1408,2666	998,2386	0,9217	99	1,1047	0,1700
	2	1383,0305	1091,2395	0,9250	99	1,0688	0,1700
	3	1376,9175	1138,0619	0,9259	99	1,0483	0,1700
1900	1	1490,2074	1017,0818	0,9215	99	1,1361	0,2050
	2	1481,2740	1169,4025	0,9257	99	1,0923	0,2050
	3	1483,0261	1223,1702	0,9268	99	1,0657	0,2050
2400	1	1727,2474	1191,1761	0,9250	99	1,1102	0,1550
	2	1723,4881	1362,1101	0,9294	99	1,0779	0,1550
	3	1724,4438	1421,8761	0,9305	99	1,0579	0,1550
2800	1	1926,3609	1332,8231	0,9274	99	1,1011	0,1250
	2	1912,9954	1510,9341	0,9319	99	1,0649	0,1250
	3	1851,1251	1519,4258	0,9323	99	1,0442	0,1250

Tablica 6.17. BBB za m=1 bez dodanih prekida u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]	Razlika MOS vrijedosti	**Prosječna procijenjena propusnost [kbit/s]**	**Prosječna propusnost odabrane razine [kbit/s]**	**SSIM**	**Broj prebacivanja razina kvalitete**	**Dubina prebacivanja razina kvalitete**	**Početno kašnjenje [s]**
700	1	872,0480	614,0154	0,9113	99	1,1459	0,3550
	2	846,4219	671,4227	0,9139	99	1,0973	0,3550
	3	860,5704	718,1721	0,9150	99	1,0667	0,3550
1100	1	1120,3320	792,2738	0,9168	99	1,1154	0,2350
	2	1118,1643	886,5014	0,9204	99	1,0740	0,2350
	3	1112,1476	923,1715	0,9211	99	1,0528	0,2350
1500	1	1328,0174	933,0370	0,9203	99	1,1045	0,1800
	2	1314,8465	1035,1727	0,9239	99	1,0656	0,1800
	3	1301,0564	1074,2769	0,9247	99	1,0481	0,1800
1900	1	1430,4419	965,4954	0,9204	99	1,1367	0,2150
	2	1401,1148	1104,1945	0,9245	99	1,0893	0,2150
	3	1426,0945	1180,9535	0,9260	99	1,0664	0,2150
2400	1	1652,7502	1148,4679	0,9243	99	1,1136	0,1600
	2	1613,2087	1273,5861	0,9280	99	1,0761	0,1600
	3	1642,1214	1354,3727	0,9294	99	1,0539	0,1600
2800	1	1804,7325	1257,3660	0,9263	99	1,0950	0,1300
	2	1815,5417	1432,2276	0,9307	99	1,0671	0,1300
	3	1781,4252	1464,1967	0,9315	99	1,0451	0,1300

Tablica 6.18. BBB za m=1,3 bez dodanih prekida u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]	Razlika MOS vrijedosti	**Prosječna procijenjena propusnost [kbit/s]**	**Prosječna propusnost odabrane razine [kbit/s]**	**SSIM**	**Broj prebacivanja razina kvalitete**	**Dubina prebacivanja razina kvalitete**	**Početno kašnjenje [s]**
700	1	852,0506	589,4447	0,9104	99	1,1496	0,3600
	2	827,5672	652,3451	0,9131	99	1,0974	0,3600
	3	833,4632	691,8297	0,9143	99	1,0691	0,3600
1100	1	1092,6407	778,3399	0,9165	99	1,1229	0,2450
	2	1059,7726	838,6413	0,9191	99	1,0785	0,2450
	3	1085,9388	899,6075	0,9205	99	1,0568	0,2450
1500	1	1286,2827	912,4748	0,9199	99	1,0984	0,1850
	2	1292,7408	1022,3799	0,9236	99	1,0656	0,1850
	3	1274,1422	1048,7005	0,9241	99	1,0504	0,1850
1900	1	1404,8172	967,8453	0,9205	99	1,1388	0,2200
	2	1356,7822	1067,9764	0,9237	99	1,0945	0,2200
	3	1382,2076	1143,2161	0,9252	99	1,0700	0,2200
2400	1	1607,3374	1118,2521	0,9238	99	1,1150	0,1650
	2	1587,5164	1255,2051	0,9277	99	1,0781	0,1650
	3	1582,6248	1305,0239	0,9288	99	1,0484	0,1650
2800	1	1760,6644	1219,4274	0,9257	99	1,1026	0,1350
	2	1750,4274	1374,9632	0,9298	99	1,0639	0,1350
	3	1745,1347	1428,6075	0,9309	99	1,0480	0,1350

Tablica 6.19. BBB za m=0,7 s dodanim prekidima u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]	Razlika MOS vrijedosti	Prosječna procijenjena propusnost [kbit/s]	Prosječna propusnost odabrane razine [kbit/s]	SSIM	Duljina zastoja	Broj zastoja	Broj prebacivanja razina kvalitete	Dubina prebacivanja razina kvalitete	Početno kašnjenje [s]
700	1	812,663	500,681	0,901	197,711	7,290	88,510	1,212	0,335
	2	810,792	606,535	0,907	187,266	3,400	90,320	1,146	0,335
	3	834,081	666,071	0,910	197,658	1,000	92,000	1,106	0,335
1100	1	1041,692	628,642	0,905	170,283	5,290	89,330	1,208	0,225
	2	1085,362	802,361	0,913	176,460	1,750	91,530	1,136	0,225
	3	1086,810	861,614	0,916	203,081	1,000	93,450	1,100	0,225
1500	1	1274,248	763,446	0,909	131,112	1,890	90,690	1,201	0,170
	2	1289,256	932,024	0,917	176,800	1,000	92,640	1,130	0,170
	3	1292,744	1019,562	0,920	224,296	1,000	94,990	1,096	0,170
1900	1	1338,853	778,060	0,909	162,862	4,170	90,000	1,225	0,205
	2	1383,158	1009,071	0,917	205,039	2,810	92,110	1,148	0,205
	3	1383,205	1089,782	0,920	248,665	2,690	94,120	1,111	0,205
2400	1	1606,563	929,877	0,913	126,782	1,000	91,650	1,224	0,155
	2	1600,979	1158,047	0,921	196,000	1,000	93,910	1,145	0,155
	3	1631,523	1271,748	0,924	219,892	1,000	95,510	1,106	0,155
2800	1	1762,249	1002,174	0,914	191,987	4,070	91,940	1,212	0,125
	2	1796,298	1294,105	0,923	197,116	1,000	94,380	1,136	0,125
	3	1800,841	1393,556	0,926	255,778	1,670	96,590	1,100	0,125

Tablica 6.20. BBB za m=1 s dodanim prekidima u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]	Razlika MOS vrijedosti	Prosječna procijenjena propusnost [kbit/s]	Prosječna propusnost odabrane razine [kbit/s]	SSIM	Duljina zastoja	Broj zastoja	Broj prebacivanja razina kvalitete	Dubina prebacivanja razina kvalitete	Početno kašnjenje [s]
700	1	796,756	489,857	0,901	194,341	6,730	88,570	1,213	0,355
	2	784,165	586,769	0,907	165,070	2,640	90,100	1,143	0,355
	3	789,311	632,953	0,909	220,722	2,770	91,560	1,105	0,355
1100	1	992,208	617,272	0,905	151,669	3,760	89,620	1,211	0,235
	2	1009,649	751,069	0,912	181,666	1,690	91,620	1,135	0,235
	3	1043,421	831,080	0,915	250,289	2,600	93,610	1,100	0,235
1500	1	1229,452	736,681	0,909	128,287	1,850	90,610	1,204	0,180
	2	1235,416	910,315	0,916	172,620	1,000	92,290	1,124	0,180
	3	1250,515	985,561	0,919	215,837	1,000	94,510	1,094	0,180
1900	1	1311,580	757,325	0,908	194,209	5,640	90,210	1,229	0,215
	2	1323,801	967,589	0,917	166,741	1,000	92,190	1,150	0,215
	3	1307,057	1031,825	0,919	255,477	2,620	94,270	1,109	0,215
2400	1	1508,790	879,100	0,911	147,842	2,630	90,990	1,222	0,160
	2	1518,585	1103,131	0,920	195,036	1,000	93,490	1,140	0,160
	3	1526,961	1193,939	0,923	227,311	1,000	95,300	1,107	0,160
2800	1	1669,052	966,927	0,913	188,577	4,090	91,540	1,204	0,130
	2	1678,458	1207,879	0,922	179,162	1,000	93,930	1,130	0,130
	3	1704,739	1329,148	0,925	219,054	1,000	95,730	1,099	0,130

Tablica 6.21. BBB za m=1,3 s dodanim prekidima u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]	Razlika MOS vrijedosti	Prosječna procijenjena propusnost [kbit/s]	Prosječna propusnost odabrane razine [kbit/s]	SSIM	Duljina zastoja	Broj zastoja	Broj prebacivanja razina kvalitete	Dubina prebacivanja razina kvalitete	Početno kašnjenje [s]
700	1	758,592	468,925	0,900	113,838	2,940	88,600	1,220	0,360
	2	763,103	568,400	0,906	141,039	1,000	90,520	1,149	0,360
	3	779,315	628,023	0,909	205,367	1,540	92,040	1,108	0,360
1100	1	995,822	609,230	0,905	114,461	1,940	89,660	1,204	0,245
	2	989,853	738,092	0,912	169,946	1,000	91,780	1,133	0,245
	3	1011,304	804,713	0,915	215,667	1,000	93,620	1,103	0,245
1500	1	1167,054	704,419	0,908	189,390	5,500	90,170	1,203	0,185
	2	1195,863	881,163	0,916	207,772	2,160	92,420	1,131	0,185
	3	1218,491	959,697	0,918	215,371	1,000	94,450	1,098	0,185
1900	1	1272,573	744,129	0,908	127,043	1,840	90,380	1,227	0,220
	2	1291,577	939,079	0,916	195,682	2,170	92,340	1,146	0,220
	3	1298,305	1026,189	0,919	209,756	1,000	93,700	1,109	0,220
2400	1	1463,569	861,997	0,911	150,898	2,600	91,130	1,215	0,165
	2	1494,035	1085,246	0,920	178,949	1,000	93,160	1,143	0,165
	3	1484,262	1162,231	0,922	211,203	1,000	95,110	1,103	0,165
2800	1	1680,062	959,936	0,913	175,140	3,730	91,390	1,209	0,135
	2	1672,697	1207,990	0,922	198,020	1,000	94,390	1,136	0,135
	3	1651,739	1285,463	0,925	223,775	1,000	96,260	1,100	0,135

7. ZAKLJUČAK

MPEG DASH standard za dinamičko prilagodljivo videostrujanje putem protokola za prijenos hiperteksta razvijen je kako bi omogućio interoperabilnost različitih rješenja za videostrujanje, smanjio cijenu razvoja i održavanja aplikacija za videostrujanje te omogućio glatku reprodukciju videosignala s najboljom mogućom kvalitetom s obzirom na promjenjive mrežne uvjete. MPEG DASH sustavi imaju korisničku stranu komunikacije koja koristi algoritme za prilagodljivi izbor razina kvalitete odnosno reprezentacije videosignala u skladu s mrežnim uvjetima te poslužiteljsku stranu koja osigurava niz reprezentacija istog videosignala koje se razlikuju po kodnoj brzini, razini kvalitete te prostornoj i vremenskoj rezoluciji. U usporedbi s korisničkom stranom aplikacije koja se intenzivno istražuje zadnji godina, poslužiteljska strana još nije dovoljno istražena te je potrebno dodatno istražiti i poboljšati odabir parametara reprezentacija prije segmentacije i kodiranja videosignala. Većina postojećih rješenja za odabir parametara reprezentacija su ili zaštićena kao industrijska rješenja, ili imaju visoku cijenu razvoja i održavanja ili oduzimaju puno vremena zbog probnog kodiranja videosignala. Također, pojedine predložene metode ne uzimaju u obzir složenost sadržaja. Stoga se u ovoj disertaciji predlaže metodologija i matematički zapis za metodu odabira optimalnih razina kvalitete u postupku kodiranja i segmentacije videosignala za prilagodljivo videostrujanje. Predložena metoda uzima u obzir prostorne, SI, i vremenske, TI, informacije koje opisuju složenost videosadržaja.

Razvoj metode za odabir optimalnih razina kvalitete u postupku kodiranja i segmentacije videosignala za prilagodljivo videostrujanje podijeljen je u dva dijela. U prvom dijelu predložena je metoda za odabir optimalnih kodnih brzina za promjene prostorne rezolucije. Kako bi se razvila metoda za odabir optimalnih mjesta promjene prostorne rezolucije, provedeno je nekoliko preliminarnih koraka ispitivanja. Skupovi videosignala korišteni u modeliranju i kasnije u ispitivanju predloženih metoda odabrani su uzimajući u obzir prostorne i vremenske informacije videosadržaja. Također, u procesu modeliranja korištena je SSIM objektivna metoda za ocjenu kvalitete videosignala zbog dobre korelacije s subjektivnom ocjenom kvalitete videosignala različitih prostornih rezolucija. SSIM vrijednosti izračunate za sve videosignale i 5 različitih prostornih rezolucija pokazuju da je u nekim rasponima prijenosnih brzina kvaliteta videosignala na nižoj prostornoj rezoluciji bolja nego na višoj prostornoj rezoluciji. Na mjestima presjeka krivulja ovisnosti SSIM vrijednosti i prijenosnih brzina za svaku prostornu rezoluciju, utvrđene su optimalne točke promjene prostorne rezolucije za svaki videosignal.

Ugrožđavanjem točaka promjene prostorne rezolucije pomoću Lloydovog algoritma određeno je da je daljnjem modeliranju potrebno koristiti dva grozda. Videosignali s umnoškom SI i TI (SITI parametar) nižim od 500 pripali su tako prvom grozdu, a videosignali s umnoškom SI i TI većim od 500 pripali su drugom grozdu. Predložena metoda za odabir optimalnih mjesta promjene prostorne rezolucije opisana je funkcijskom ovisnosti (za tu promjenu) optimalnih prijenosnih brzina o prostornoj rezoluciji i prostorno-vremenskoj informaciji videosadržaja iskazane kroz parametar SITI .

Ispitivanje predložene metode provedeno je statističkom analizom, subjektivnim ispitivanjem i ispitivanjem pomoću algoritama za prilagodljivo videostrujanja. Iz statističke analize ostvarenih rezultata, može se zaključiti da je u 85% slučajeva razlika između izračunatih optimalnih vrijednosti prijenosne brzine i izvornih izmjerenih vrijednosti manja od 20,83%, a u svim slučajevima veća razlika dogodila se na nižim prostornim rezolucijama i pri nižim vrijednostima prijenosne brzine. Zbog kasnijih kompenzacija i činjenice da je manje reprezentacija na najmanjoj prostornoj rezoluciji, postotna razlika za najnižu prostornu rezoluciju ne utječe u velikoj mjeri na rezultate ispitivanja.

Eksperimentalni dio subjektivnog ispitivanja proveden je s 28 neiskusnih gledatelja u kontroliranom okruženju. Dobiveni MOS rezultati potvrdili su da su optimalne točke promjene između susjednih prostornih rezolucija dobro odabrane s obzirom na to da su razlike MOS vrijednosti za videosignale kodirane na susjednim rezolucijama i na istoj (metodom određenoj) optimalnoj kodnoj brzini bile blizu nule. Posljednja faza ispitivanja bila je ispitivanje kvalitete segmentiranih videosignala pomoću sustava za videostrujanje s dva različita mrežna ispitna zapisa i dva algoritma za prilagodljivo videostrujanje, LIU i SARA. Kvaliteta videosignala segmentiranih korištenjem predloženog modela uspoređena je primjenom SSIM metrike s Lederer segmentacijom, a ostvareni rezultati su pokazali da predložena segmentacija poboljšava kvalitetu videozapisa u 83% slučajeva. Iz sva tri provedena vrednovanja metode za odabir optimalne kodne brzine za promjenu prostorne rezolucije pokazuju da je ovom metodom poboljšan postupak segmentacije videosignala za sustave zasnovane na MPEG DASH normi, a treba naglasiti da je istovremeno pojednostavljen postupak odabira točaka promjene prostorne rezolucije.

U drugom dijelu razvoja metode za odabir optimalnih razina kvalitete, predložena je metoda za odabir broja i parametara reprezentacija. Za ovu metodu korištene su točke anvelopa krivulja ovisnosti SSIM vrijednosti o prijenosnoj brzini. Predložena metoda za odabir broja i parametara reprezentacija opisana je funkcijskom ovisnosti SSIM vrijednosti o prijenosnoj brzini i prostorno-

vremenskoj informaciji videosadržaja iskazanoj s parametrom SITI. Također, izvedena je funkcija za procjenu vrijednosti subjektivne ocjene kvalitete u ovisnosti o prijenosnoj brzini i prostorno-vremenskoj informaciji videosadržaja preko SSIM vrijednosti određenih predloženom metodom.

Ispitivanjem predložene metode za odabir optimalnih razina kvalitete utvrđeno je da segmentacija prema predloženoj metodi ostvaruje veće vrijednosti SSIM-a u odnosu na Lederer segmentaciju u 92% slučajeva. Stoga, predložena segmentacija predstavlja poboljšanje prethodno dostupne segmentacija, optimalni skup reprezentacija odabire se uzimajući u obzir prostornu i vremensku aktivnost videosignala te se pritom isključuje potrebu za probnim kodiranjem. Također, korištenjem predložene segmentacije, za videosignale s malom vrijednosti parametra SITI smanjuje se broj reprezentacija, što znači da je potrebno i manje memorije na poslužitelju za pohranjivanje videosegmenata. Prethodno navedeni zaključci potvrđeni su subjektivnim ispitivanjem kvalitete kodiranih videosignala.

Predložena metoda za odabir optimalnih razina kvalitete u postupku kodiranja i segmentacije videosignala za prilagodljivo videostrujanje može se koristiti za određivanje skupova reprezentacija uzimajući samo parametre prostorne i vremenske informacije odabranih videosignala. Parametre SI i TI potrebno je izračunati samo jednom, za izvorni videosignal, a zatim se na osnovu jednostavnog postupka mogu odabrati optimalne prijenosne brzine i odgovarajuće prostorne rezolucije. Jednostavnost upotrebe predložene metode za odabir skupova reprezentacija njegova je najveća prednost u odnosu na postojeće metode, koje uglavnom uključuju višestruko probno kodiranje na različitim brzinama i prostornim rezolucijama te izračun kvalitete tako dobivenih kodiranih videosignala. Treba uzeti u obzir da je predložena metoda razvijena analizom videosignala kodiranih određenim koderom (H.264), tako da se predstavljeni parametri u matematičkim izrazima ne mogu koristiti za druge kodere poput H.265 ili V9. Međutim, predstavljena metodologija omogućava da se predložena metoda može lako prilagoditi drugom tipu kodera ili drugim parametrima kodiranja. Nadalje, metoda koristi SSIM ocjenu kvalitete videosignala, ali se može prilagoditi bilo kojoj drugoj objektivnoj metodi za ocjenu kvalitete videosignala.

Prilikom razvoja predložene metode i ispitivanja iste uočeni su nedostatci u bazama koje sadrže videosignale kodirane i segmentirane prema MPEG DASH normi, uključujući pripadajuće početne segmente za inicijalizaciju dekodera i MPD datoteke u nekoliko različitih profila. Stoga je u drugom dijelu istraživanja predložena baza videosignala segmentiranih prema predloženim metodama za odabir broja i parametara reprezentacija koje ostvaruju veće vrijednosti SSIM-a u

odnosu na prethodno dostupna rješenja. Predložena baza sastoji se od šest videosignala, videosignala BBB korištenog u ispitivanju predloženih metoda te pet novih videosignala koji do sada nisu bili dostupni u bazama videosignala: *Butterfly* (BT), *Trainstation1* (TS1), *Trainstation2* (TS2), *Leaves* (LE) i *Pidgeons* (PG). Kako bi se baza mogla koristiti u sustavima zasnovanim na MPEG DASH normi duljina odabranih videosignala jednaka je ili veća od 120 sekundi. Uz bazu segmentiranih videosignala dostupni su i izvorni videosignali, početni segmenti potrebni za inicijalizaciju dekodera te MPD datoteke u pet različitih profila: *full, live, main, onDemand* i *live* profil proširen informacijama o veličinama pojedinih vidoesegmenata.

Kako bi se riješili problemi dugotrajnosti ispitivanja parametara kvalitete korisničkog iskustva pomoću aplikacija za videostrujanje i utjecaja parametara kodiranja i segmentacije videosignala na kvalitetu videosignala nakon strujanja, u okviru ovog doktorskog rada razvijen je okvir za analizu i optimizaciju parametara algoritama za videostrujanje prilagodljivo mrežnim uvjetima zasnovano na MPEG DASH normi. Ovaj okvir omogućava da se na temelju podataka o segmentima (duljina i veličina segmenta), SI i TI vrijednosti videosignala te SSIM (ili neke druge objektivne mjere kvalitete) vrijednosti za pojedinu reprezentaciju, uz korištenje izmjerenih ili umjetno generiranih mrežnih zapisa, provede sustavno ispitivanje utjecaja velikog broja i raspona parametara u relativno kratkom vremenu. Kako bi se omogućilo sustavno ispitivanje utjecaja mrežnih uvjeta na rezultate videostrujanja, razvijen je i ugrađen u okvir modul koji ima mogućnost računalnog generiranja mrežnih ispitnih zapisa koji odgovaraju uvjetima u 3G i 4G mrežama. U dostupnoj literaturi usporedba rješenja za videostrujanje se radi ili pomoću izmjerenih mrežnih zapisa iz dostupnih baza za 3G ili 4G mreže ili pomoću pojednostavljenih računalno generiranih mrežnih ispitnih zapisa. Iako izmjereni mrežni zapisi predstavljaju realne uvjete, nisu u potpunosti prikladni za sustavnu analizu algoritama za prilagodljivo videostrujanje zbog velike raznolikosti statističkih svojstava i ograničene dostupnosti.

Kako bi se riješio ovaj problemi, predloženi okvir za analizu i optimizaciju parametara algoritama za videostrujanje proširen je modulom za umjetno generiranje mrežnih ispitnih zapisa pomoću parametara Nakagami raspodjele vjerojatnosti koja se može koristiti za modeliranje dostupne propusnosti. Rezultati simulacija videostrujanja pomoću LIU algoritma za prilagodljivo videostrujanje, pokazali su da umjetno generirani mrežni ispitni zapisi dobro oponašaju izmjerene ako je procijenjeni parametar m veći od 0,7. Rezultati simulacije za prosječnu razinu kvalitete, procijenjenu dostupnu propusnost, odabranu prijenosnu brzinu, broj prebacivanja razina kvalitete i prosječnu dubinu prebacivanja razina kvalitete postignute za umjetno generirane mrežne ispitne

zapise bili su vrlo bliski rezultatima postignutim izmjerenim mrežnim ispitnim zapisima. Može se zaključiti da se Nakagami distribucija može koristiti za modeliranje i generiranje umjetnih ispitnih zapisa propusnosti u širokom rasponu parametara za ispitivanje algoritama za prilagodljivo videostrujanje.

Razvijeni okvir za analizu i optimizaciju parametara algoritama za videostrujanje iskorišten je za usporedbu predložene segmentacije i Lederer segmentacije za različite mrežne uvjete ostvarene primjenom različitih vrijednosti parametara Nakagami distribucije. Provedeno ispitivanje je pokazalo da predložena segmentacija ostvaruje veće SSIM vrijednosti neovisno o uvjetima u mreži te da se povećanjem vrijednosti parametara m i ω povećavaju i postotne razlike između ostvarenih SSIM vrijednosti za predloženu i Lederer segmentaciju. Također, predložena segmentacija ima manji broj prebacivanja razina kvalitete i manju dubinu prebacivanja razine kvalitete što povoljno utječe na kvalitetu korisničkog iskustva. Jedini parametar koji je lošiji za predloženu segmentaciju je početno kašnjenje koje veće do 12% u odnosu na početno kašnjenje za Lederer segmentaciju, ali je ovaj nedostatak kompenziran značajno manjim brojem i duljinom zastoja u mrežnim uvjetima kada dolazi do zastoja u reprodukciji videosignala.

Nadalje, primjenom razvijenog okvira provedeno je ispitivanje utjecaja razlike MOS vrijednosti između susjednih reprezentacija na parametre kvalitete korisničkog iskustva. Ispitivanjima je utvrđeno da kada se koriste videosignali sa velikom prostorno-vremenskom aktivnosti, potrebno je koristiti razliku MOS vrijednosti 3 (prema MOS skali 0-100) kao korak između susjednih reprezentacija jer se na taj način ostvaruju najveće vrijednosti SSIM-a. Kada se koriste videosignali s manjom prostorno-vremenskom aktivnosti, potrebno je koristiti razliku MOS vrijednosti 1 ili 2 kako bi se osigurao kompromis između broja i dubine prebacivanja razina kvalitete, broja i duljine trajanja zastoja u reprodukciji videosignala i SSIM vrijednosti.

U okviru ovog doktorskog rada predložena je metoda za odabir optimalnih razina kvalitete u postupku kodiranja i segmentacije videosignala za prilagodljivo videostrujanje, baza videosignala kodiranih i segmentiranih prema predloženoj metodi te okvir za analizu i optimizaciju parametara algoritama za videostrujanje prilagodljivo mrežnim uvjetima zasnovano na MPEG DASH normi.

Ovime su postignuti sljedeći izvorni znanstveni doprinosi:

1. Metoda za odabir optimalnih razina kvalitete u postupku kodiranja i segmentacije videosignala za prilagodljivo videostrujanje zasnovana na prostorno-vremenskim značajkama videosadržaja

2. Vrednovanje metode za odabir optimalnih razina kvalitete videosignala za prilagodljivo videostrujanje

3. Baza kodiranih i segmentiranih videosignala sa skupom parametara za prilagodljivo videostrujanje zasnovano na MPEG DASH normi

4. Okvir za analizu i optimizaciju parametara algoritama za videostrujanje prilagodljivo mrežnim uvjetima zasnovano na MPEG DASH normi

LITERATURA

[1] Cisco, "Cisco Visual Networking Index: Forecast and Methodology 2016-2021" http://www.cisco.com/c/en/us/solutions/collateral/service-provider/visual-networking-index-vni/complete-white-paper-c11-481360.html, pristup 22. lipnja 2021.

[2] T.C. Thang, H. Le, A. Pham, Y.M. Ro, "An Evaluation of Bitrate Adaptation Methods for HTTP Live Streaming", IEEE Journal on Selected Areas in Communications, br. 4, sv. 32, str. 693–705, ožujak 2014.

[3] L. Toni, R. Aparicio-Pardo, K. Pires, G. Simon, A. Blanc, P. Frossard, "Optimal Selection of Adaptive Streaming Representations", ACM Transactions on Multimedia Computing Communications and Applications, br. 2s, sv. 11, str. 1–26, veljača 2015.

[4] S. Lederer, C. Miiller, C. Tinnnerer, "Dynamic adaptive streaming over HTTP dataset", 3rd Multimedia Systems Conference, str. 89-94, Chapel Hill, 2012.

[5] A.V. Katsenou, F. Zhang, K. Swanson, M. Afonso, J. Sole, D. Bull, "VMAF-based Bitrate Ladder Estimation for Adaptive Streaming" https://arxiv.org/pdf/2103.07564.pdf, pristup 22. lipnja 2021.

[6] J. De Cock, Z. Li, M. Manohara A. Aaron, "Complexity-based consistent-quality encoding in the cloud, IEEE International Conference on Image Processing", str. 1484-1488, Phoenix, 2016.

[7] A. Moldovan, I. Ghergulescu, C.H. Muntean, "VQAMap: A Novel Mechanism for Mapping Objective Video Quality Metrics to Subjective MOS Scale", IEEE Transactions on Broadcasting, br.3, sv. 62, str. 610-627, lipanj 2016.

[8] J. Kovačević, G. Miljković, V. Mihić, K. Lazić, „Advanced Rate Adaptation Algorithm in Video Streaming Over HTTP", 2014 IEEE Fourth International Conference on Consumer Electronics, str. 78–82, Berlin, 2014.

[9] K. Lazić, I. Basičević, J. Kovačević, „Bandwidth estimation in adaptive video streaming over HTTP", 2015 IEEE Fifth International Conference on Consumer Electronics, str. 62–65, Las Vegas, 2015.

[10] J. Kovačević, G. Miljković, K. Lazić, M. Stankić, „Evaluation of adaptive streaming algorithms over HTTP", 2013 Third IEEE International Conference on Consumer Electronics, str. 1–4, Berlin, 2013.

[11] C. Mueller, S. Lederer, C. Timmerer, H. Hellwagner, „Dynamic Adaptive Streaming over HTTP/2.0, 2013 IEEE International Conference on Multimedia and Expo", str. 1–6, San Jose, 2013.

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

[13] S. Lederer, C. Mueller, B. Rainer, M. Waltl, C. Timmerer, “An open source MPEG DASH evaluation suite,” 2012 IEEE Visual Communications and Image Processing, str. 1-1, San Diego, 2012.

[14] K. Lazić, M. Milošević, G. Miljković, N. Ikonić, J. Kovačević, “One Implementation of Dynamic Adaptive Streaming over HTTP,” 2012 20th Telecommunications Forum, str. 1496–1499, Beograd, 2012.

[15] Y. Reznik, K. Lillevold, A. Jagannath, J. Greer, J. Corley, “Optimal Design of Encoding Profiles for ABR Streaming” http://www.reznik.org/papers/PV2018_streaming.pdf, pristup 22. lipnja 2021.

[16] A. Zabrovskiy, C. Feldmann, C. Timmerer, “Multi-codec DASH dataset”, 9th ACM Multimedia Systems Conference, str. 438–443, Amsterdam, 2018.

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

[18] T.Y. Huang, R. Johari, N. McKeown, M. Trunnell, M. Watson, “A buffer-based approach to rate adaptation: evidence from a large video streaming service”, ACM SIGCOMM Computer Communication Review, br. 4, sv. 44, str. 187–198, listopad 2015.

[19] L. Bedogni, M. Di Felice, L. Bononi, “Dynamic segment size selection in HTTP based adaptive video streaming”, IEEE Conference on Computer Communications Workshops”, str. 665-670, Atlanta, 2017.

[20] Y.M. Hassan, A. Helmy, M.M. Rehan, “Effect of varying segment size on DASH streaming quality for mobile user”, International Conference on Engineering and Technology, str. 1-4, Kairo, 2014.

[21] S. Wilk, D. Stohr, W. Effelsberg, “A content-aware video adaptation service to support mobile video”, ACM Transactions on Multimedia Computing, Communications, and Applications, br. 5s, sv. 12, str. 1-23, studeni 2016.

[22] S. Schwarzmann, T. Zinner, S. Geissler, C. Sieber, “Evaluation of the Benefits of Variable Segment Durations for Adaptive Streaming”, Tenth International Conference on Quality of Multimedia Experience, str. 1-6, Sardinija, 2018.

[23] G. Luis, I. Satoru, A. Toru, S. Takuo, “SAND/3: SDN-Assisted Novel QoE Control Method for Dynamic Adaptive Streaming over HTTP/3”, Electronics, br. 9, sv. 8, str. 1-17, kolovoz 2019.

[24] S. Lederer, C. Mueller, C. Timmerer, C. Concolato, J. Le Feuvre, K. Fliegel, "Distributed DASH dataset", 4th ACM Multimedia Systems Conference on Multimedia Systems, str. 131–135, Oslo, 2013.

[25] K. Miller, E. Quacchio, G. Gennari, A. Wolisz, "Adaptation algorithm for adaptive streaming over HTTP", 19th International Packet Video Workshop, str. 173–178, Berlin, 2012.

[26] D. Yun, K. Chung, "DASH-based Multi-view Video Streaming System", IEEE Transactions on Circuits and Systems for Video Technology", br. 8, sv. 28, str. 1974-1980, kolovoz 2018.

[27] S. Basso, A. Servetti, E. Masala, J. C. De Martin, "Measuring DASH Streaming Performance from the End Users Perspective using Neubot", str. 1–6, Singapur, 2014.

[28] D. J. Vergados, A. Michalas, A. Sgora, D. D. Vergados, P. Chatzimisios, "FDASH: A fuzzy-based MPEG/DASH adaptation algorithm", IEEE Systems Journal, br. 2, sv. 10, str. 859–868, lipanj 2016.

[29] C. Liu, I. Bouazazi, M. Gabbouj, "Rate adaptation for adaptive HTTP streaming", Second annual ACM conference on Multimedia systems, str. 169-174, San Jose, 2011.

[30] S. Zhao, Z. Li, D. Medhi, P. Lai, S. Liu, "Study of user QoE improvement for dynamic adaptive streaming over HTTP (MPEG-DASH)", 2017 International Conference on Computing, Networking and Communications, str. 566–570, Silicon Valley, 2017.

[31] R. K. P. Mok, X. Luo, E. W. W. Chan, R. K. C. Chang, "QDASH : A QoE-aware DASH system", Third Multimedia Systems Conference, str. 11–22, Chapel Hill, 2012.

[32] D. Suh, I. Jang, S. Pack, "QoE-enhanced Adaptation Algorithm over DASH for Multimedia Streaming", The International Conference on Information Networking 2014, str. 497–501, Phuket, 2014.

[33] H. Zhang, X. Jiang, "A QOE-driven approach to rate adaptation for dynamic adaptive streaming over http", 2016 IEEE International Conference on Multimedia & Expo Workshops, str. 1-6, Seattle, 2016.

[34] A. H. Zahran, C. J. Sreenan, "Arbiter: adaptive rate-based intelligent HTTP streaming algorithm", IEEE International Conference on Multimedia & Expo Workshops, str. 425–431, Seattle, 2015.

[35] W. Ur Rahman, D. Yun, K. Chung, "A client side buffer management algorithm to improve QoE", IEEE Transactions on Consumer Electronics, br. 4, sv. 62, str. 371–379, studeni 2016.

[36] L. Yu, T. Tillo, J. Xiao, "QoE-Driven Dynamic Adaptive Video Streaming Strategy With Future Information", IEEE Transactions on Broadcasting, br. 3, sv. 63, str. 1–12, travanj 2017.

[37] P. Juluri, V. Tamarapalli, D. Medhi, „SARA: Segment aware rate adaptation algorithm for dynamic adaptive streaming over HTTP“, IEEE International Conference on Communication Workshop, str. 1765-1770, London, 2015.

[38] S. Lee, E. Lee, H. Lee, “Quality adaptation scheme for improving QoE of MPEG DASH”, 2016 International Conference on Information and Communication Technology Convergence, str. 368–370, Jeju, 2016.

[39] M. Seyedebrahimi, X. H. Peng, C. Bailey, “Client QoE-oriented segment selection for DASH”, 2015 IEEE International Conference on Computer and Information Technology; Ubiquitous Computing and Communications; Dependable, Autonomic and Secure Computing; Pervasive Intelligence and Computing, str. 1663–1668, Liverpool, 2015.

[40] M. Kim, J. Park, K. Chung, “Content-aware Rate Adaptation Scheme to Improve Stability in HTTP Adaptive Streaming”, 2017 International Conference on Information Networking, str. 401–405, Da Nang, 2017.

[41] T. Huang, R. Johari, N. McKeown, M. Trunnell, M. Watson, “A buffer-based approach to rate adaptation: Evidence from a large video streaming service”, ACM SIGCOMM Computer Communication Review, b4. 4, sv. 44, pp. 187–198, kolovoz 2014.

[42] Y. Chen, K. Wu, Q. Zhang, “From QoS to QoE: A tutorial on video quality assessment”, IEEE Communications Surveys & Tutorials, br. 2, sv. 17, str. 1126–1165, listopad 2015.

[43] International Telecommunication Union, “ITU-T G.1080 Quality of experience requirements for IPTV services” https://www.itu.int/rec/dologin_pub.asp?lang=e&id=T-REC-G.1080-200812-I!!PDF-E&type=items, pristup 22. lipnja 2021.

[44] K. Brunnström, S.A. Beker, K. de Moor, A. Dooms, S. Egger, M.-N. Garcia, T. Hossfeld, S. Jumisko-Pyykkö, C. Keimel, M.-C. Larabi, “Qualinet white paper on definitions of quality of experience” https://hal.archives-ouvertes.fr/hal-00977812/document, pristup 22. lipnja 2021.

[45] G. Pibiri, C. Mc Goldrick, M. Huggard, “Expected Quality of Service (eQoS) A network metric for capturing end-user experience”, IFIP Wireless Days, str. 1-6, Dublin, 2012.

[46] S. Möller, A. Raake, Alexander, Quality of Experience: Advanced Concepts, Applications and Methods, Springer, London, 2014.

[47] B. Villa, P. Heegaard, „Improving Fairness in QoS and QoE domains for Adaptive Video Streaming“, The International Journal on Advances in Networks and Services, str. 291-303, St. Maarten, 2012.

[48] N. Cranley, P. Perry, L. Murphy, “User perception of adapting video quality“, International Journal of Human-Computer Studies, br. 8, sv. 64, str. 637–647, kolovoz 2006.

[49] Z. Duanmu, K. Zeng, K. Ma, A. Rehman, Z. Wang, “A Quality-of-Experience Index for Streaming Video”, IEEE Journal of Selected Topics in Signal Processing, br. 1, sv. 11, str. 154–166, rujan 2017.

[50] H. K. Yarnagula, S. Luhadia, S. Datta, V. Tamarapalli, “Quality of experience assessment of rate adaptation algorithms in DASH: An experimental study”, 2016 8th International Conference on Communication Systems and Networks, str. 1–8, Bangalore, 2016.

[51] C. Zhang, J. Liu, F. Chen, Y. Cui, E. C. Ngai, “Dependency-Aware Caching for HTTP Adaptive Streaming”, 2016 Digital Media Industry & Academic Forum, str. 89–93, Santorini, 2016.

[52] A. Sobhani, A. Yassine, S. Shirmohammadi, “QoE-Driven Optimization for DASH Service in Wireless Networks”, 2016 IEEE International Symposium on Multimedia, str. 232-237, San Jose, 2016.

[53] D. Z. Rodríguez, S. Member, R. L. Rosa, E. C. Alfaia, J. I. Abrahão, G. Bressan, “Video Quality Metric for Streaming Service Using DASH Standard”, IEEE Transactions on Broadcasting, br. 3, sv. 62, str. 1–12, rujan 2016.

[54] G. Tian, Y. Liu, ”Towards Agile and Smooth Video Adaptation in Dynamic HTTP Streaming”, IEEE/ACM Transactions on Networking, br. 4, sv. 24, str. 109-120, prosinac 2012.

[55] J. Kua, G. Armitage, P. Branch, "A Survey of Rate Adaptation Techniques for Dynamic Adaptive Streaming Over HTTP", IEEE Communications Surveys & Tutorials, br. 3, sv. 19, str. 1842-1866, ožujak 2017.

[56] T. Karagkioules, C. Concolato, D. Tsilimantor, S. Valentin, “A Comparative Case Study of HTTP Adaptive Streaming Algorithms in Mobile Networks”, 27th Workshop on Network and Operating Systems Support for Digital Audio and Video, str. 1-6, Taipei, 2017.

[57] A. Abdelsalam, M. Luglio, M. Quadrini, C. Roseti, F. Zampognaro, "Evaluation of DASH Algorithms on Dynamic Satellite-Enhanced Hybrid Networks", 2018 International Symposium on Advanced Electrical and Communication Technologies, str. 1-6, Rabat, 2018.

[58] Orange Open Movie Project, „Elephants Dream“ https://orange.blender.org/, pristup 22. lipnja 2021.

[59] Peach Open Movie Project, „Big Buck Bunny“ https://peach.blender.org/, pristup 22. lipnja 2021.

[60] S. Lederer, C. Miiller, C. Tinnnerer, “Dynamic adaptive streaming over HTTP dataset” https://dash.itec.aau.at/dash-dataset/, pristup 22. lipnja 2021.

[61] B. Hubert, J. Geul, S. Séhier, „The Wonder Shaper 1.4.1“ https://github.com/magnific0/wondershaper, pristup 22. lipnja 2021.

[62] R. Rassool, "VMAF reproducibility: Validating a perceptual practical video quality metric", 2017 IEEE International Symposium on Broadband Multimedia Systems and Broadcasting, str. 1-2, Cagliari, 2017.

[63] C. G. Bampis, A. C. Bovik, “Feature-based prediction of streaming video QoE: Distortions rebuffering and memory”, Signal Processing: Image Communication, br. 7, sv. 68, str. 218–228, listopad 2018.

[64] C. G. Bampis, Z. Li, I. Katsavounidis, A. C. Bovik, “Recurrent and dynamic models for predicting streaming video quality of experience”, IEEE Transations on Image Processing, br. 7, sv. 27, str. 3316–3331, srpanj 2018.

[65] S. Winkler, P. Mohandas, „The Evolution of Video Quality Measurement: From PSNR to Hybrid Metrics“, IEEE Transactions on Broadcasting, br. 4, sv. 54, str. 660 –668, srpanj 2008.

[66] International Telecommunication Union, “P.910 : Subjective video quality assessment methods for multimedia applications“ https://www.itu.int/rec/T-REC-P.910-200804-I, pristup 22. lipnja 2021.

[67] C. Kreuzberger, D. Posch, H. Hellwagner, “A Scalable Video Coding Dataset and Toolchain for Dynamic Adaptive Streaming over HTTP”, 6th ACM Multimedia Systems Conference, str. 213–218, Portland, 2015.

[68] J. Lee, F. De Simone, T. Ebrahimi, “Subjective Quality Evaluation via Paired Comparison : Application to Scalable Video Coding”, IEEE Transactions on Multimedia, br. 5, sv. 13, str. 882–893, svibanj 2011.

[69] G. Zhai, J. Cai, S. Member, W. Lin, S. Member, “Cross-Dimensional Perceptual Quality Assessment for Low Bit-Rate Videos”, IEEE Transactions on Multimedia, br. 7, sv. 10, str. 1316–1324, listopad 2008.

[70] Z. Wang, A. Bovik, H. Sheikh, “Image Quality Assessment: From Error Visibility to Structural Similarity”, IEEE Transactions on Image Processing, br. 4, sv. 13, str. 600-612, travanj 2004.

[71] FFmpeg project, „FFmpeg“ https://www.ffmpeg.org/, pristup 22. lipnja 2021.

[72] C.G.Bampis, Z. Li, I. Katsavounidis, T.Y. Huang, C. Ekanadham, A.C. Bovik, “Towards Perceptually Optimized Adaptive Video Streaming -A Realistic Quality of Experience Database“, IEEE Transactions on Image Processing, sv. 30, str. 5182-5197, travanj 2021.

[73] Xiph.org, „Video Test Media“ https://media.xiph.org/video/derf/, pristup 22. lipnja 2021.

[74] International Telecommunication Union, “ITU-T P.800. Methods for Subjective Determination of Transmission Quality - Series P: Telephone Transmission Quality; Methods for Objective and Subjective Assessment of Quality“ https://www.itu.int/rec/dologin_pub.asp?lang=e&id=T-REC-P.800-199608-I!!PDF-E&type=items, pristup 22. lipnja 2021.

[75] International Telecommunication Union, “ITU-T P.913: Methods for the subjective assessment of video quality, audio quality and audiovisual quality of Internet video and distribution quality television in any environment“ https://www.itu.int/rec/dologin_pub.asp?lang=e&id=T-REC-P.913-201603-I!!PDF-E&type=items, pristup 22. lipnja 2021.

[76] K. De Moor, I. Ketyko, W. Joseph, T. Deryckere, L. De Marez, L. Martens, G. Verleye, “Proposed framework for evaluating quality of experience in a mobile, testbed-oriented living lab setting“, Mobile Networks and Applications, br. 3, sv. 15, str. 378–391, lipanj 2010.

[77] R.K.P. Mok, E.W.W. Chan, X. Luo, R.K.C. Chang, “Inferring the QoE of HTTP video streaming from user-viewing activities“, ACM SIGCOMM workshop on Measurements up the stack, str. 31–36, Toronto, 2011.

[78] H-J. Park, D-H. Har, “Subjective Image Quality Assessment based on Objective Image Quality Measurement Factors”, IEEE Transactions on Consumer Electronics, br. 3, sv. 57, str. 1176-1184, kolovoz 2011.

[79] S. Chikkerur, V. Sundaram, M. Reisslein, L. J. Karam, “Objective video quality assessment methods: A classification, review, and performance comparison”, IEEE Transactions on Broadcasting, br. 2, sv. 57, str. 165–182, lipanj 2011.

[80] Z. Wang, L. Lu, A. C. Bovik, “Video quality assessment based on structural distortion measurement”, Signal Processing: Image Communication, br. 2, sv. 19, str. 121–132, veljača 2004.

[81] Z. Wang, E. P. Simoncelli, “Reduced-reference image quality assessment using a wavelet-domain natural image statistic model”, Electronic Imaging, str. 149–159, San Jose, 2005.

[82] A. Mittal, M. A. Saad, A. C. Bovik, “A completely blind video integrity oracle”, IEEE Transactions on Image Processing, br. 1, sv. 25, str. 289–300, siječanj 2016.

[83] N. Nighi, N. Aggarwal, “A review on Video Quality Assessment”, 2014 Recent Advances in Engineering and Computational Sciences, str. 1-6, Chandigarh 2014.

[84] D. Vatolin, M. Smirnov, A. Ratushnyak, V. Yoockin, “MSU Quality Measurement Tool” www.compression.ru/video/quality_measure/video_measurement_tool.html, pristup 22. lipnja 2021.

[85] C. Yang, L. Zhao, Z. Liao, “Objective Quality Metric Based on Perception for Video”, International Conference on Computer Engineering and Technology, str. 20-23, Singapur, 2009.

[86] Z. Wang, E.P. Simoncelli, A. C. Bovik, "Multiscale structural similarity for image quality assessment", The Thrity-Seventh Asilomar Conference on Signals, Systems & Computers, str. 1398-1402, Pacific Grove, 2003.

[87] D.M. Chandler, S.S. Hemami, "VSNR: A wavelet-based visual signal-to-noise ratio for natural images", IEEE Transactions on Image Processing, br. 9, sv. 16, str. 2284-2298, kolovoz 2007.

[88] M. Pinson, S. Wolf, “A new standardized method for objectively measuring video quality”, IEEE Transactions on Broadcasting, br. 3, sv. 50, str. 312–322, rujan 2004.

[89] P. Orosz, T. Skopkó, Z. Nagy, P. Varga, L. Gyimóthi, “A case study on correlating video QoS and QoE”, IEEE Network Operations and Management Symposium, str. 1-5, Kraków, 2014.

[90] V. Deksnys, E. Sakalauskas, G. Činčikas, “New integral quality of TV service criterion construction based on quality of experience statistical estimation”, 14th Biennial Baltic Electronic Conference, str. 149–152, Tallinn, 2014.

[91] R. Koshimura, Y. Ito, Y. Nomura, “Empirical study on clarification of relationship between QoS and QoE for Web services by path analysis”, 3rd Global Conference on Consumer Electronics, str. 10-11, Tokio, 2014.

[92] International Telecommunication Union, “ITU-T P.10 Vocabulary for performance, quality of service and quality of experience” https://www.itu.int/rec/dologin_pub.asp?lang=e&id=T-REC-P.10-201711-I!!PDF-E&type=items, pristup 22. lipnja 2021.

[93] M. Zink, J. Schmitt, R. Steinmetz, “Layer-encoded Video in Scalable Adaptive Streaming”, IEEE Transactions on Multimedia, br. 1, sv. 7, str. 75–84, veljača 2005.

[94] T. Zinner, O. Hohlfeld, Osama Abboud, T. Hossfeld, “Impact of Frame Rate and Resolution on Objective QoE Metrics”, Second International Workshop on Quality of Multimedia Experience, str. 29-34, Trondheim, 2010.

[95] M. Vranješ, S. Rimac-Drlje, D. Žagar, “Subjective and Objective Quality Evaluation of the H.264/AVC Coded Video”, 15th International Conference on Systems, Signals and Image Processing, str. 287 – 290, Bratislava, 2008.

[96] C. G. Bampis, Z. Li, A. C. Bovik, "Spatiotemporal Feature Integration and Model Fusion for Full Reference Video Quality Assessment", IEEE Transactions on Circuits and Systems for Video Technology, br. 8, sv. 29, str. 2256-2270, kolovoz 2019.

[97] D. Vranješ, D. Žagar, O. Nemčić, "Comparison of objective quality assessment methods for scalable video coding", ELMAR-2012, str. 19-22, Zadar, 2012.

[98] Z. Duanmu, K. Ma, Z. Wang, "Quality-of-Experience for Adaptive Streaming Videos: An Expectation Confirmation Theory Motivated Approach", IEEE Transactions on Image Processing, br. 12, sv. 27, str. 6135-6146, srpanj 2018.

[99] W. Kirch, Pearson's Correlation Coefficient, Springer, Dordrecht, 2008.

[100] R. Aparicio-Pardo, K. Pires, A. Blanc, G. Simon, "Transcoding Live Adaptive Video Streams at a Massive Scale in the Cloud", 6th ACM Multimedia Systems Conference (2015), str. 49-60, Portland, 2015.

[101] W. Zhang, Y. Wen, Z. Chen, A. Khisti, "QoE-Driven Cache Management for HTTP Adaptive Bit Rate Streaming Over Wireless Networks", IEEE Transactions on Multimedia, br. 6, sv. 15, str. 1431–1445, veljača 2013.

[102] C. Kreuzberger, B. Rainer, H. Hellwagner, L. Toni, P. Frossard, "A comparative study of DASH representation sets using real user characteristics", 26th International Workshop on Network and Operating Systems Support for Digital Audio and Video, str. 1–6, Klagenfurt, 2016.

[103] L. Toni, R. Aparicio-Pardo, G. Simon, A. Blanc, P. Frossard, "Optimal set of video representations in adaptive streaming", 5th ACM Multimedia Systems Conference (2014), str. 271–282, Singapur, 2014.

[104] Z. Duanmu, A. Rehman, Z. Wang, "A Quality-of-Experience Database for Adaptive Video Streaming", IEEE Transactions on Broadcasting, br. 2, sv. 64, str. 474-487, lipanj 2018.

[105] C. Fan, S. Yen, C. Huang, C. Hsu, "On the Optimal Encoding Ladder of Tiled 360° Videos for Head-Mounted Virtual Reality", IEEE Transactions on Circuits and Systems for Video Technology, br. 4, sv. 31, str. 1632-1647, srpanj 2020.

[106] C. Chen, Y. Lin, S. Benting, A. Kokaram, "Optimized Transcoding for Large Scale Adaptive Streaming Using Playback Statistics", 25th IEEE International Conference on Image Processing, str. 3269-3273, Atena, 2018.

[107] C. Li, L. Toni, P. Frossard, H. Xiong, J. Zou, "Complexity constrained representation selection for dynamic adaptive streaming", Visual Communications and Image Processing, str. 1-4, Chengdu, 2016.

[108] The VideoLAN project, ".x264, software library" https://www.videolan.org/developers/x264.html, pristup 22. lipnja 2021.

[109] J. Le Feuvre, C. Concolato, J.-C. Dufourd, R. Bouqueau, J.-C. Moissinac, “Experimenting with Multimedia Advances using GPAC”, ACM Conference on Multimedia (2011), str. 715-718, Scottsdale, 2011.

[110] S. Lloyd, “Least Squares Quantization in PCM”, IEEE Transactions on Information Theory, br. 2, sv. 28, str. 129–137, ožujak 1982.

[111] P. Juluri, V. Tamarapalli, D. Medhi, “AStream: A rate adaptaion model for DASH” https://github.com/pari685/AStream, pristup 22. lipnja 2021.

[112] J. J. Quinlan, A. H. Zahran, C. J. Sreenan, “Datasets for AVC (H.264) and HEVC (H.265) evaluation of dynamic adaptive streaming over HTTP (DASH)”, 7th International Conference on Multimedia Systems, str. 1–6, Klagenfurt, 2016.

[113] J. Le Feuvre, J-M. Thiesse, M. Parmentier, M. Raulet, C. Daguet, “Ultra high definition HEVC DASH dataset”, 5th ACM Multimedia Systems Conference (2014), str. 7–12, Singapur, 2014.

[114] D. Sretenovic, V. Pekovic, V. Zlokolica, D. Kukolj, M. Temerinac, “Test stream generation framework for video quality assessment methodology evaluation” 19thTelecommunications Forum, str. 1163-1166, Beograd, 2011.

[115] J. Yan, W. Muhlbauer, B. Plattner, "Analytical Framework for Improving the Quality of Streaming Over TCP," IEEE Transactions on Multimedia, br. 6, sv. 14, str. 1579-1590, prosinac 2012.

[116] A. Zabrovskiy, E. Kuzmin, E. Petrov, C. Timmerer, C. Mueller, “AdViSE: Adaptive Video Streaming Evaluation Framework for the Automated Testing of Media Players”, 8th ACM on Multimedia Systems Conference, str. 217-220, Taipei, 2017.

[117] B. Rainer, M. Waltl, C. Timmerer, Christian, “A Web based Subjective Evaluation Platform”, 5th International Workshop on Quality of Multimedia Experience, str. 24-25, Klagenfurt am Wörthersee, 2013.

[118] C. Timmerer, A. Zabrovskiy, “Automating QoS and QoE Evaluation of HTTP Adaptive Streaming System”https://res-www.zte.com.cn/mediares/magazine/publication/com_en/article/201901/en201901004.pdf, pristup 22. lipnja 2021.

[119] S. Göring, A. Raake, B. Feiten, “A Framework for QoE Analysis of Encrypted Videos Streams”, Ninth International Conference on Quality of Multimedia Experience, str. 1-3, Erfurt, 2017.

[120] X. Yin, A. Jindal, V. Sekar, B. Sinopoli, “A Control-Theoretic Approach for Dynamic Adaptive Video Streaming over HTTP”, ACM Conference on Special Interest Group on Data Communication, str. 325–338, London, 2015.

[121] M. Mezzavilla, M. Zhang, M. Polese, R. Ford, S. Dutta, S. Rangan, M. Zorzi, "End-to-End Simulation of 5G mmWave Networks", IEEE Communications Surveys & Tutorials, br. 3, sv. 20, str. 2237-2263, travanj 2018.

[122] D. Raca, D. Leahy, C. J. Sreenan, J. J. Quinlan, “Beyond throughput, the next generation: a 5G dataset with channel and context metrics”, 11th ACM Multimedia Systems Conference, str. 303–308, Istanbul, 2020.

[123] L.F. Huang, “The Nakagami and its related distributions”, WSEAS Transaction on Mathematics, sv. 15, str. 477-485, kolovoz 2016.

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

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

SAŽETAK

MPEG standard za promjenjivo prilagodljivo strujanje putem HTTP-a (MPEG DASH) definira format videosegmenata i manifest datoteke. Razvijena je kako bi se osigurala interoperabilnost između različitih aplikacija za videostrujanje koje se koriste za prijenos videosignala od poslužitelja prema korisničkoj aplikaciji, istovremeno osiguravajući najvišu moguću kvalitetu videosignala u različitim mrežnim uvjetima. Uzimajući u obzir da su dostupna istraživanja uglavnom usredotočena na poboljšanje algoritama za prilagodljivo videostrujanje i da predložene metode za pripremu prezentacija videosignala na poslužiteljskoj strani ne uzimaju u obzir prostornu i vremensku aktivnost videosadržaja, koriste veliku računalnu snage za probno kodiranje ili su zaštićene autorskim pravima, u ovoj je disertaciji predložena nova metoda za odabir optimalnih parametara za skupove reprezentacija u postupku kodiranja i segmentacije.

Prvi dio istraživanja predstavljen u ovom doktorskom radu usredotočen je na odabir parametara za kodiranje i segmentaciju videosignala metodom koja uzima u obzir prostornu i vremensku aktivnost videosadržaja i ne zahtijeva probno kodiranje svakog videosignala. Predstavljena je metodologiju korištena za razvoj metode te matematički zapisi koji omogućavaju optimalan izbor prijenosnih brzina i odgovarajućih prostornih rezolucija za reprezentacije segmentiranog videosignala na poslužiteljskoj strani. U usporedbi sa segmentacijom dostupnom u relevantnoj literaturi, segmentacija videosignala zasnovana na predloženim metodom ostvaruje veće vrijednosti indeksa strukturne sličnosti SSIM u 92% slučajeva.

Tijekom razvoja i ispitivanja predloženih metoda, uočeno je da postoji nedostatak videosignala kodiranih i segmentiranih prema MPEG DASH normi te je u drugom dijelu istraživanja predložena baza od šest videosignala segmentiranih prema predloženoj metodi za odabir broja i parametara reprezentacija. Uz segmente u trajanju od 2, 6 i 10 sekundi, predložena baza videosignala uključuje izvorne videosignale, inicijalizacijske segmente i MPD datoteke u pet različitih profila.

Simulacijski okvir koji se može koristiti za usporedbu različitih algoritama za prilagodljivo videostrujanje pomoću QoE parametara i za istraživanje utjecaja parametara segmentacije na ostvarenu kvalitetu videozapisa, razvijen je s obzirom da nema dostupnih rješenja koja se mogu koristiti bez pristupa Internet mreži i bez potrebe za segmentacijom videosignala pri svakoj promjeni parametara kodiranja. Predloženi okvir također uključuje modul za umjetno generiranje mrežnih ispitnih zapisa primjenom Nakagami raspodjele vjerojatnosti.

Usporedbom parametara koji utječu na kvalitetu prenesenog videosignala dobivenih primjenom umjetno generirane i izmjerene mrežne ispitne zapise, pokazalo se da se Nakagami raspodjela vjerojatnosti može koristiti za umjetno generiranje mrežnih ispitnih zapisa koji odgovaraju širokom rasponu izmjerenih mrežnih ispitnih zapisa za 3G i 4G mreže.

Posljednji dio istraživanja proveden je korištenjem predloženog okvira za ispitivanje utjecaja razlike u MOS vrijednostima korištenim za određivanje optimalnog broja reprezentacija na parametre QoE. Predložena segmentacija postiže veće SSIM vrijednosti bez obzira na mrežne uvjete i ima manji broj i dubinu prebacivanja razina kvalitete. Predloženi okvir također je korišten kako bi se potvrdila pretpostavka da bi razlika u MOS vrijednostima koja se koristi za određivanje optimalnog broja reprezentacija trebala biti veća ako se koriste videosignali s višim prostornim i vremenskim informacijama. Iz rezultata simulacije može se zaključiti da bi za segmentiranje videosignala s višim vrijednostima SI i TI razlika MOS vrijednosti trebala biti tri (za MOS skalu od 0-100), a kada se koriste videosignali s nižim vrijednostima SI i TI, razlika MOS vrijednosti koja se koristi za određivanje optimalnog broja reprezentacija trebala bi biti jedan ili dva kako bi se osigurao kompromis između broja i dubine prebacivanja razina kvalitete, broja i trajanja zastoja u reprodukciji videosignala i SSIM vrijednosti.

Ključne riječi: prilagodljivo videostrujanje, segmentacija videosignala, MPEG DASH, QoE, okvir za videostrujanje

ABSTRACT

A standard called MPEG Dynamic Adaptive Streaming over HTTP (MPEG DASH) defines the format of video segments and the manifest file. It was developed to ensure interoperability between various video streaming application used for transferring video sequences from a server to the client while ensuring the highest possible video quality in the varying network conditions. Considering that the available research mostly focuses on improving the adaptive streaming algorithms and that the proposed methods for selecting the optimal parameters for the representation sets do not consider the spatial and temporal activity of video sequences, use a high amount of computational power for precoding, or are proprietary, there is room for improvement.

The first part of the research presented in this doctoral dissertation is focused on the selection of parameters for coding and segmentation of video signals using a method that takes into account the spatial and temporal activity of video content and does not require trial coding of each video signal. Considering that some of the proposed solutions lack the information needed for the reproduction of results, this doctoral dissertation includes the methodology used for developing the methods and the notation for all methods presented in this doctoral dissertation. Compared to the segmentation available in the relevant literature, the segmentation of video signals based on the proposed methods obtains better Structural Similarity Index Measure values in 92% of cases.

During the development of the proposed methods and its testing, it was noticed that there is a lack of video signals encoded and segmented according to MPEG DASH standard, in the second part of the research a database of six video signals segmented according to the proposed methods for selecting the number and parameters of representations was presented. In addition to the segments with a duration of 2, 6, and 10 seconds, the proposed database includes source video signals, initialization segments, and MPD files in five different profiles.

The simulation framework that can be used for comparing different adaptation algorithms based on QoE parameters and for investigating the influence of segmentation parameters on the resulting video quality, was developed considering there weren't any available solutions that could be used offline without the need for segmentation of video signals for every change in coding parameters. The proposed framework also includes the module for generating synthetic network traces by using Nakagami distribution.

By comparing the parameters that affect the quality of the uploaded video using synthetic and measured network traces, it was shown that the Nakagami distribution can be used for generating synthetic network traces that correspond to a wide range of measured network traces.

The last part of the research was conducted using the proposed framework for examining the impact of the difference in MOS values used to determine the optimal number of representations on the QoE parameters. The proposed segmentation achieves higher SSIM values regardless of the network conditions and has a smaller number and depth of quality level switching. The proposed framework was also used to confirm the premise that the difference in MOS values used to determine the optimal number of representations should be higher if video signals with higher spatial and temporal information are used. From simulation results, it can be concluded that for segmenting video signals with higher values of SI and TI, the difference of MOS value should be three, and when video signals with lower values SI and TI are used, the difference of MOS value used to determine the optimal number of representations should be one or two to ensure a compromise between the number and depth of switching quality levels, the number, and duration of video playback delays and SSIM values.

Keywords: adaptive video streaming, segmentation of video signals, MPEG DASH, QoE, video streaming framework

ŽIVOTOPIS

Jelena Vlaović rođena je 11. prosinca 1989. godine u Osijeku gdje završava osnovnu i srednju školu. 2008. godine upisuje sveučilišni preddiplomski studij elektrotehnike, smjer Komunikacije i informatika na Elektrotehničkom fakultetu Osijek gdje je 2011. godine stekla titulu prvostupnice elektrotehnike. Po završetku preddiplomskog studija upisuje sveučilišni diplomski studij elektrotehnike, smjer Komunikacije i informatika na kojem 2013. godine stječe titulu magistre inženjerke elektrotehnike, smjer Komunikacije i informatika. 2013. godine dobiva stručnu praksu u *Siemens Convergence Creators* u Osijeku. Po završetku sveučilišnog diplomskog studija elektrotehnike, smjer Komunikacije i informatika upisuje sveučilišni diplomski studij elektrotehnike, smjer Elektroenergetika i zapošljava se na Elektrotehničkom fakultetu Osijek na projektu „Jačanje položaja žena na tržištu rada“ financiranom iz Europske Unije na mjestu asistenta voditelja projekta. 2015. godine upisuje poslijediplomski doktorski studij elektrotehnike, smjer Komunikacije i informatika i zapošljava se na Elektrotehničkom fakultetu Osijek na mjestu asistenta gdje radi i danas. 2016. godine stječe titulu magistre inženjerke elektrotehnike, smjer Elektroenergetika. Osim prethodno navedenog obrazovanja Jelena ima položen *Deutsches Sprachdiplom* C1-napredna razina, *Cambridge* ispit, C1-napredna razina te završenu A1 razinu talijanskog jezika. Uz to je tijekom studiranja položila dva *Microsoft Technology Associate* certifikata: *Networking Fundamentals* i *Database Administration Fundamentals* te je prošla tečaj prodajnih vještina u organizaciji HT-a. Tijekom studiranja upisuje i završava od MZOS-a priznate tečajeve web dizajna i web programiranja u školi Edunova te tečaj za CAD specijalista u Algebri. 2016. godine postaje certificirani instruktor Mikrotik akademije, završava tečajeve za pisanje i provedbu EU projekata te 2018. završava Vector-ove edukacije za CANoe, CANape, Flexray i XCP. Također je tijekom studiranja bila korisnik stipendije Nacionalne zaklade za potporu učeničkom i studentskom standardu te stipendije Osječko-baranjske županije za poslijediplomski studij. 2016. godine dobija stipendiju za financiranje mobilnosti u okviru programa Erasumus Euroweb + te odlazi na znanstveno i stručno usavršavanje u Novi Sad u trajanju 6 mjeseci. Od 2015. do 2016. godine surađuje s Institutom RT-RK d.o.o. na projektu razvoja elektronskog programskog vodiča za automobilsku industriju. Autor je 26 znanstvenih i stručnih radova.

PRILOZI

Prilog P.1. MPD datoteka za videosignal *Butterfly* (BT) u profilu *full*

```
<?xml version="1.0"?>

<!-- MPD file Generated with GPAC version 0.8.0-rev1-gc1990d5c-master  at 2021-05-09T16:28:14.850Z-->

<MPD xmlns="urn:mpeg:dash:schema:mpd:2011" minBufferTime="PT1.500S" type="static"
mediaPresentationDuration="PT0H2M2.920S" maxSegmentDuration="PT0H0M12.920S"
profiles="urn:mpeg:dash:profile:full:2011">

 <ProgramInformation moreInformationURL="http://gpac.io">

  <Title>1_120_2s.mpd generated by GPAC</Title>

 </ProgramInformation>

 <Period duration="PT0H2M2.920S">

  <AdaptationSet segmentAlignment="true" bitstreamSwitching="true" group="1" maxWidth="480"
maxHeight="360" maxFrameRate="25" par="4:3" lang="und" startWithSAP="1">

   <SegmentList>

    <Initialization sourceURL="1_120_2s_set1_init.mp4"/>

   </SegmentList>

   <Representation id="1" mimeType="video/mp4" codecs="avc3.4D400D" width="320" height="240"
frameRate="25" sar="1:1" bandwidth="46736">

    <SegmentList timescale="25000" duration="250000">

     <SegmentURL media="1_1_120_10s1.m4s"/>

     <SegmentURL media="1_1_120_10s2.m4s"/>

     <SegmentURL media="1_1_120_10s3.m4s"/>

     <SegmentURL media="1_1_120_10s4.m4s"/>

     <SegmentURL media="1_1_120_10s5.m4s"/>

     <SegmentURL media="1_1_120_10s6.m4s"/>

     <SegmentURL media="1_1_120_10s7.m4s"/>

     <SegmentURL media="1_1_120_10s8.m4s"/>

     <SegmentURL media="1_1_120_10s9.m4s"/>

     <SegmentURL media="1_1_120_10s10.m4s"/>

     <SegmentURL media="1_1_120_10s11.m4s"/>

     <SegmentURL media="1_1_120_10s12.m4s"/>

    </SegmentList>

   </Representation>
```

Prilog P.2. MPD datoteka za videosignal *Butterfly* (BT) u profilu *live*

```
<?xml version="1.0"?>

<!-- MPD file Generated with GPAC version 0.8.0-rev1-gc1990d5c-master  at 2021-05-09T16:21:34.545Z-->

<MPD xmlns="urn:mpeg:dash:schema:mpd:2011" minBufferTime="PT1.500S" type="static"
mediaPresentationDuration="PT0H2M2.920S" maxSegmentDuration="PT0H0M12.920S"
profiles="urn:mpeg:dash:profile:isoff-live:2011">

 <ProgramInformation moreInformationURL="http://gpac.io">

  <Title>1_120_2s.mpd generated by GPAC</Title>

 </ProgramInformation>

 <Period duration="PT0H2M2.920S">

  <AdaptationSet segmentAlignment="true" bitstreamSwitching="true" group="1" maxWidth="480"
maxHeight="360" maxFrameRate="25" par="4:3" lang="und" startWithSAP="1">

   <SegmentTemplate media="$RepresentationID$_1_120_10s$Number$.m4s"
initialization="1_120_2s_set1_init.mp4" timescale="25000" startNumber="1" duration="250000"/>

   <Representation id="1" mimeType="video/mp4" codecs="avc3.4D400D" width="320" height="240"
frameRate="25" sar="1:1" bandwidth="46736">

   </Representation>

   <Representation id="2" mimeType="video/mp4" codecs="avc3.4D4015" width="480" height="360"
frameRate="25" sar="1:1" bandwidth="87048">

   </Representation>

   <Representation id="3" mimeType="video/mp4" codecs="avc3.4D4015" width="480" height="360"
frameRate="25" sar="1:1" bandwidth="181544">

   </Representation>

  </AdaptationSet>

  <AdaptationSet segmentAlignment="true" group="1" maxWidth="854" maxHeight="480" maxFrameRate="25"
par="854:480" lang="und" startWithSAP="1">

   <SegmentTemplate media="$RepresentationID$_1_120_10s$Number$.m4s"
initialization="$RepresentationID$_1_120_10s.mp4" timescale="25000" startNumber="1" duration="250000"/>

   <Representation id="4" mimeType="video/mp4" codecs="avc3.4D401E" width="854" height="480"
frameRate="25" sar="1:1" bandwidth="287672">

   </Representation>

  </AdaptationSet>

  <AdaptationSet segmentAlignment="true" bitstreamSwitching="true" group="1" maxWidth="1920"
maxHeight="1080" maxFrameRate="25" par="16:9" lang="und" startWithSAP="1">

   <SegmentTemplate media="$RepresentationID$_1_120_10s$Number$.m4s"
initialization="1_120_2s_set3_init.mp4" timescale="25000" startNumber="1" duration="250000"/>

   <Representation id="5" mimeType="video/mp4" codecs="avc3.4D401F" width="1280" height="720"
frameRate="25" sar="1:1" bandwidth="512968">

   </Representation>
```

Prilog P.3. MPD datoteka za videosignal *Butterfly* (BT) u profilu *main*

```
<?xml version="1.0"?>

<!-- MPD file Generated with GPAC version 0.8.0-rev1-gc1990d5c-master  at 2021-05-09T16:31:02.187Z-->

<MPD xmlns="urn:mpeg:dash:schema:mpd:2011" minBufferTime="PT1.500S" type="static"
mediaPresentationDuration="PT0H2M2.920S" maxSegmentDuration="PT0H0M12.920S"
profiles="urn:mpeg:dash:profile:isoff-main:2011">

 <ProgramInformation moreInformationURL="http://gpac.io">

  <Title>1_120_2s.mpd generated by GPAC</Title>

 </ProgramInformation>

 <Period duration="PT0H2M2.920S">

  <AdaptationSet segmentAlignment="true" bitstreamSwitching="true" group="1" maxWidth="480"
maxHeight="360" maxFrameRate="25" par="4:3" lang="und" startWithSAP="1">

   <SegmentList>

    <Initialization sourceURL="1_120_2s_set1_init.mp4"/>

   </SegmentList>

   <Representation id="1" mimeType="video/mp4" codecs="avc3.4D400D" width="320" height="240"
frameRate="25" sar="1:1" bandwidth="46736">

    <SegmentList timescale="25000" duration="250000">

     <SegmentURL media="1_1_120_10s1.m4s"/>

     <SegmentURL media="1_1_120_10s2.m4s"/>

     <SegmentURL media="1_1_120_10s3.m4s"/>

     <SegmentURL media="1_1_120_10s4.m4s"/>

     <SegmentURL media="1_1_120_10s5.m4s"/>

     <SegmentURL media="1_1_120_10s6.m4s"/>

     <SegmentURL media="1_1_120_10s7.m4s"/>

     <SegmentURL media="1_1_120_10s8.m4s"/>

     <SegmentURL media="1_1_120_10s9.m4s"/>

     <SegmentURL media="1_1_120_10s10.m4s"/>

     <SegmentURL media="1_1_120_10s11.m4s"/>

     <SegmentURL media="1_1_120_10s12.m4s"/>

    </SegmentList>

   </Representation>
```

Prilog P.4. MPD datoteka za videosignal *Butterfly* (BT) u profilu *onDemand*

```
<?xml version="1.0"?>

<!-- MPD file Generated with GPAC version 0.8.0-rev1-gc1990d5c-master  at 2021-05-10T17:38:08.590Z-->

<MPD xmlns="urn:mpeg:dash:schema:mpd:2011" minBufferTime="PT1.500S" type="static"
mediaPresentationDuration="PT0H2M2.920S" maxSubsegmentDuration="PT0H0M12.920S"
profiles="urn:mpeg:dash:profile:isoff-on-demand:2011">

 <ProgramInformation moreInformationURL="http://gpac.io">

  <Title>1_120_2s.mpd generated by GPAC</Title>

 </ProgramInformation>

 <Period duration="PT0H2M2.920S">

  <AdaptationSet segmentAlignment="true" group="1" maxWidth="480" maxHeight="360" maxFrameRate="25"
par="4:3" lang="und" startWithSAP="1" subsegmentAlignment="true" subsegmentStartsWithSAP="1">

   <Representation id="1" mimeType="video/mp4" codecs="avc1.4D400D" width="320" height="240"
frameRate="25" sar="1:1" bandwidth="46736">

    <BaseURL>1_1_120_10s.mp4</BaseURL>

    <SegmentBase indexRangeExact="true" indexRange="825-1000">

     <Initialization range="0-824"/>

    </SegmentBase>

   </Representation>

   <Representation id="2" mimeType="video/mp4" codecs="avc1.4D4015" width="480" height="360"
frameRate="25" sar="1:1" bandwidth="87048">

    <BaseURL>2_1_120_10s.mp4</BaseURL>

    <SegmentBase indexRangeExact="true" indexRange="826-1001">

     <Initialization range="0-825"/>

    </SegmentBase>

   </Representation>

   <Representation id="3" mimeType="video/mp4" codecs="avc1.4D4015" width="480" height="360"
frameRate="25" sar="1:1" bandwidth="181544">

    <BaseURL>3_1_120_10s.mp4</BaseURL>

    <SegmentBase indexRangeExact="true" indexRange="826-1001">

     <Initialization range="0-825"/>

    </SegmentBase>

   </Representation>

  </AdaptationSet>
```

Prilog P.5. MPD datoteka za videosignal *Butterfly* (BT) u proširenom profilu *live*

```
<?xml version="1.0"?>

<!-- MPD file Generated with GPAC version 0.8.0-rev1-gc1990d5c-master  at 2021-05-09T16:21:34.545Z-->

<MPD xmlns="urn:mpeg:dash:schema:mpd:2011" minBufferTime="PT1.500S" type="static"
mediaPresentationDuration="PT0H2M2.920S" maxSegmentDuration="PT0H0M12.920S"
profiles="urn:mpeg:dash:profile:isoff-live:2011">

 <ProgramInformation moreInformationURL="http://gpac.io">

  <Title>1_120_2s.mpd generated by GPAC</Title>

 </ProgramInformation>

 <Period duration="PT0H2M2.920S">

  <AdaptationSet segmentAlignment="true" bitstreamSwitching="true" group="1" maxWidth="480"
maxHeight="360" maxFrameRate="25" par="4:3" lang="und" startWithSAP="1">

   <Representation id="1" mimeType="video/mp4" codecs="avc3.4D400D" width="320" height="240"
frameRate="25" sar="1:1" bandwidth="46736">

   <SegmentTemplate media="$RepresentationID$_1_120_10s_$Number$.m4s"
initialization="1_120_2s_set1_init.mp4" timescale="25000" startNumber="1" duration="250000"/>

    <SegmentSize id="1_1_120_10s_1.m4s"            size="4392.0" scale="Kbits"/>

          <SegmentSize id="1_1_120_10s_2.m4s"    size="4536.0" scale="Kbits"/>

          <SegmentSize id="1_1_120_10s_3.m4s"    size="4568.0" scale="Kbits"/>

          <SegmentSize id="1_1_120_10s_4.m4s"    size="4584.0" scale="Kbits"/>

          <SegmentSize id="1_1_120_10s_5.m4s"    size="4704.0" scale="Kbits"/>

          <SegmentSize id="1_1_120_10s_6.m4s"    size="4648.0" scale="Kbits"/>

          <SegmentSize id="1_1_120_10s_7.m4s"    size="4664.0" scale="Kbits"/>

          <SegmentSize id="1_1_120_10s_8.m4s"    size="4736.0" scale="Kbits"/>

          <SegmentSize id="1_1_120_10s_9.m4s"    size="4744.0" scale="Kbits"/>

          <SegmentSize id="1_1_120_10s_10.m4s"   size="4704.0" scale="Kbits"/>

          <SegmentSize id="1_1_120_10s_11.m4s"   size="4752.0" scale="Kbits"/>

          <SegmentSize id="1_1_120_10s_12.m4s"   size="6384.0" scale="Kbits"/>

   </Representation>
```

Prilog P.6. Modul za određivanje statusa međuspremnika

```
function
[Razina,rebuffering,TDsec,network,iNuk,Nuk,To,Tv,BR,SSIM,Ruk,Psegment,Pmreze]=doprinos4(N_trace, V)
%Ts - trajanje segmenta
%Tv - trajanje videosignala
%Ds - duljina segmenta u kbit
%N - N-ti segmnet (vremenski)-brojač segemnata
%Nuk - ukupan broj segmenata
%R - R-ta reprezentacija
%Ruk - ukupan broj reprezentacija
%SR - prostorna rezolucija
%BR – prijenosna brzina kodiranog videosignala u kbit/s
%Bp - procijenjena propusnost u intervalu To, prvu vrijednost preuzeta iz
%vektora brzine
%To-vremenski interval u kojem se ne mijenja propusnost
%Buff - popunjenost međuspremnika
%BuffMin - donja granica popunjenosti međuspremnika (broj segmenata)
%BuffMax - gornja granica popunjenosti međuspremnika
%Td - trajanje početnog kašnjenja
%iNuk - broj vremenkih intervala za vrijeme trajanja videosignala,
%zaokruženo na prvi veći cijeli broj
%Bs – odabrana prijenosna brzina(reprezentacija)
%SRs - odabrana prostorna rezolucija
%sBP - srednja propusnost za vrijeme preuzimanja prethodnog segmenta
%

load('Ds.mat'); % matrica s veličinama svih segmenata

Ts=6;
Tv=596.46;
RAZ0=1; % definiranje razine kvalitete za prvi segment (razine idu od 1 do Ruk)

Ruk=20;
BR=[45.514 89.036 128.256 176.827 217.651 255.169 320.564 373.935 506.300 573.252 779.796 1006.743
1201.426 1461.530 2078.678 2395.950 2919.314 3297.198 3557.500 3858.484];

SR=[76800 76800 76800 172800 172800 172800 172800 172800 409920 409920 921600 921600 921600 921600
2073600 2073600 2073600 2073600 2073600 2073600];

PSNR=[27.1699 29.4168 30.4533 31.1906 31.8558 32.3202 32.9042 34.729 33.2353 35.1217 36.1243 37.1951
37.8457 40.406 38.4605 41.1345 42.1054 43.0224 42.6801 43.3682];

SSIM=[0.864328799 0.879708624 0.888074153 0.895434778 0.900195752 0.9038408 0.909070142 0.912599829
0.919545688 0.922392267 0.929444923 0.935299694 0.939351701 0.943843448 0.951916994 0.955172733
0.959701019 0.962490947 0.964232527 0.966094008];

Nuk=ceil(Tv/Ts);
Vs(1)=Ds(1,RAZ0); % Vs(n) je vektor veličina segmenata pohranjenih u međuspremniku (potreban za proračun
pražnjenje međuspremnika)
To=0.005;
iNuk=ceil(Tv/To)*2;

sBp=zeros(1,Nuk);
Razina=zeros(1,Nuk);
R=zeros(1,Nuk);
SRs=zeros(1,Nuk);
BRs=zeros(1,Nuk);
propustkontr=zeros(1,Nuk);
```

```
Tfn=zeros(1,Nuk);
TD=0;
k=1;
w=1;
b=1;
segment=1;

M=Ts/To;
BuffMin=1; %donja granična vrijednost popunjenosti međuspremnika
buff_seg=0;

[Bp,network]=testcase(iNuk, To, N_trace, V);

Buff=zeros(1,iNuk);
rebuffering=zeros(1,iNuk);

% proračun popunjenosti međuspremnika Buff(i) u i-tom intervalu To i odabir sljedeće razine kvalitete
(reprezentacije)

RAZ=RAZ0;% početna razine kvalitete
Razina(1)=RAZ;
Bs(1)=BR(RAZ);
SRs(1)=SR(RAZ);

brm=0; % brojač intervala To u kojima se prikazuje videosignal, tj. prazni se međuspremnik
m=0; % broj prikazanih segmenata do trenutka i*To

Buff_poc=1; %definira koliko segmenata treba biti u međuspremniku na početku prije pokretanja reprodukcije
videosignala

kTo=0;
SBuk=0;

n=1;
i=0;
rebuffering_ukupno=0;

while n<=Nuk && i<=(iNuk-1)

 i=i+1;
 SBuk=SBuk+Bp(i)*To;% SBuk je kb prenešenih u i-tom intervalu za n-ti  segment

 %Dio koji slijedi  računa početno kašnjenje
 nB=n-1;
 if nB<Buff_poc
          rebuffering(i)=2;    % 2 znači početno kašnjenje u i-tom intervalu
          TD=TD+1; % početno kašnjenje reprodukcije videosignala iskazano u broju intervala To
          TDsec=TD*To; % početno kašnjenje u sekundama
 else
          disp('nB je veći od Buff_poc');
 end
```

```
%Dio koji slijedi prazni međuspremnik za svaki To interval ako u međuspremniku ima barem 1 segment

      if  buff_seg>=1 % reprodukcija videosignala prestaje kada broj segmenata padne ispod BuffMin
          rebuffering(i)=0;
          brm=brm+1;

          if mod(brm,M)==0
            m=m+1; %broj prikazanih segmenata
          buff_seg=nB-m;
          else
          end
      elseif nB>0
          rebuffering(i)=1;% 1 znači zastoj u i-tom intervalu
          rebuffering_ukupno=rebuffering_ukupno+1;
      else
      end

%Dio koji slijedi provjerava je li preuzet cijeli segment i ako jest povećava
%popunjenost međuspremnika i poziva ABR algoritam da odabere sljedeću razinu
    if SBuk<Ds(n,RAZ)
      kTo=kTo+1; % kTo broji intervale potrebne za prijenos n-tog segmenta
    else
      kontr(n)=kTo;
      Tf=kTo*To;      % vrijeme preuzimanja za n-ti segment
      Tfn(n)=Tf;
      est_Propusnost_n=SBuk/Tf; %procijenjena propusnost za n+1 segment
      propustkontr(n)=est_Propusnost_n;

      SBuk=0;
      kTo=0;
      buff_seg=buff_seg+1;

      Buffer_all(n)=buff_seg;
      Buffer=Buffer_all(n);

    [RAZn,meanDowTime,download_rate,B]=LIU(RAZ,BR,Ruk,Tfn,segment,Vs);

    meanDT(segment)=meanDowTime;
    segment=segment+1;

    Psegment(n)=B;
    Pmreze(n)=download_rate;

    n=n+1;

    RAZ=RAZn;
    Razina(n)=RAZ;
    BRs(n)=BR(RAZ);
    SRs(n)=SR(RAZ);

    if n<=Nuk
       Vs(n)=Ds(n,RAZ);
    end
   end
   Buff(i)=buff_seg;
 end
end
```

Prilog P.7. Modul koji sadrži LIU algoritam za prilagodljivo videostrujanje

```
function [RAZn,meanDowTime,download_rate,B]=LIU(RAZ,BR,Ruk,Tfn,segment,Vs)

%LIU ili osnovni algoritam
% za rezultat program daje razinu kvalitete (reprezentaciju), RAZn za sljedeći segment
%Ulazne veličine:
%RAZ - razina kvalitete prethodnog skinutog segmenta
%Propusnost - izračunata propusnost kod prijenosa prethodnog segmenta
%BR - vektor korištenih brzina po razinama kvalitete (reprezentacijama)
%Ruk - ukupan broj reprezentacija
%Tf – vrijeme preuzimanja prethodnog segmenta

if segment == 1
   TfnSum=0.253931045532 + Tfn(segment);
   VsSum=7.016 + Vs(segment);
   meanDowTime =TfnSum / 2;
   download_rate = VsSum / (meanDowTime * 2);
elseif segment == 2
   TfnSum=0.253931045532 + Tfn(segment) + Tfn(segment-1);
   VsSum=7.016 + Vs(segment) + Vs(segment-1);
   meanDowTime =TfnSum / 3;
   download_rate = VsSum / (meanDowTime * 3);
elseif segment == 3
   TfnSum=0.253931045532 + Tfn(segment) + Tfn(segment-1)+ Tfn(segment-2);
   VsSum=7.016 + Vs(segment) + Vs(segment-1) + Vs(segment-2);
   meanDowTime =TfnSum / 4;
   download_rate = VsSum / (meanDowTime * 4);
elseif segment == 4
   TfnSum=0.253931045532 + Tfn(segment)+ Tfn(segment-1)+ Tfn(segment-2)+ Tfn(segment-3);
   VsSum=7.016 + Vs(segment)+ Vs(segment-1) + Vs(segment-2) + Vs(segment-3);
   meanDowTime =TfnSum / 5;
   download_rate = VsSum / (meanDowTime * 5);
else
   TfnSum=Tfn(segment)+Tfn(segment-1)+ Tfn(segment-2)+ Tfn(segment-3)+Tfn(segment-4);
   VsSum=Vs(segment)+ Vs(segment-1) + Vs(segment-2) + Vs(segment-3)+ Vs(segment-4);
   meanDowTime =TfnSum / 5;
   download_rate = VsSum / (meanDowTime * 5);
end

   B=Vs(segment)/Tfn(segment);

   if download_rate > BR(RAZ)*1.2
      %ako je ispunjen uvjet, provjeriti je li izračunata vrijednost manja
       od BR na zadnjoj reprezentaciji
      if RAZ >= Ruk
         RAZn=Ruk;
      %ako nije povecaj reprezentaciju za 1
      else
        RAZn=RAZ+1;
      end
   else
      % provjeriti je li izračunata vrijednost manja od BR na prvoj
       reprezentaciji
          if download_rate > BR(Ruk)
              RAZn=Ruk;
          end
          if download_rate <= BR(1)
              RAZn=1;
          else
```

```
            %pronalazak prve razine na kojoj je izračunata vrijednost
             manja od BR
            for c=1:Ruk
               if(download_rate > BR(c)*1.2)
                  RAZn = c;
               else
                  RAZn = c-1;
                  if RAZn==0
                     RAZn=1;
                  end
                  break;
               end
            end
         end
end
```

Prilog P.8. Modul za definiranje mrežnih uvjeta

```
function [Bp,network]=testcase(iNuk,To,N_trace,V)

tct=1/To;
n=ceil(iNuk/tct);
Bp=zeros(1,iNuk);
brojac=1;
K=11;

network=zeros(1,2500);
duljina=2500; % proizvoljna duljina zapisa u ovisnosti o duljini videosignala

mu_trace=[0.7 1 1.3 0.7 1 1.3 0.7 1 1.3 0.7 1 1.3 0.7 1 1.3 0.7 1 1.3];
srednjaVrijednost=1024*[700 1100 1500 1900 2400 2800];
omega_trace=zeros(1,18);

for o=1:3
   for z=1:6
   omega_trace(1,(6*(o-
1))+z)=((gamma(mu_trace(o))/gamma(mu_trace(o)+0.5))^2)*srednjaVrijednost(z)*mu_trace(o);
   end
end

mu=mu_trace(N_trace);
omega=omega_trace(N_trace);

[sinteticki]=trace_sintNkg(duljina,mu,omega,K);
network=sinteticki;

for t=1:duljina
   if network(t)<0
      network(t)=0;
   end
end

for k=1:n
            for b=brojac:(brojac+(tct-1))
         Bp(b)=network(1,k);
            end
            brojac=tct*k;
end

for st=2000:15000
        Bp(st)=10; %dodatni zastoj 1
end
for st=4500:60000
        Bp(st)=10; %dodatni zastoj 2
end

for brez=1:iNuk
   if Bp(brez)<0
      Bp(brez)=10; %korekcija ako se u gornjim petljama dobije propusnost
      manja od 0
   end
end

end
```

P.9. Postavljanje parametara Nakagami raspodjele vjerojatnosti

```
function [sinteticki]=trace_sintNkg(duljina,mu,omega,K)

% Generira Nakagami slučajni niz s parametrima mu i omega
% duljina - duljina generiranog niza
% mu - parametar oblika Nakagami raspodjele vjerojatnosti
% omega - parametar širine Nakagami raspodjele vjerojatnosti
% K - broj koeficijenata moving average filtra

srednja_vrijednost=(gamma(mu+1)/gamma(mu))*sqrt(omega/mu); %proračun srednje vrijednosti na temelju
parametara Nakagami raspodjele vjerojatnosti

Nkg=random('Nakagami',mu,omega,[duljina,1]);
gamapom=gamma(mu+0.5)/gamma(mu);
omeganovi=K*omega+gamapom^2*omega*(1-K)/(1 *mu);
mupom=omeganovi*mu/(gamapom^2*omega);

for i=1:6000
        A(i)=0.001*i;
        gA(i)=gamma(A(i)+0.5)./gamma(A(i));
end

pom=A./(gA.^2);

k=find((pom>=(mupom*0.95))&(pom<=(mupom*1.05)));

munovi=A(round(median(k)));
noviNkg=random('Nakagami',munovi,omeganovi,[duljina+K,1]);

windowSize = K;

b = (1/windowSize)*ones(1,windowSize);
a=1;

sinteticki_pros=filter(b,a,noviNkg);

%slijedi pomicanje početka mrežnog ispitnog zapisa za K kako bi se smanjio
% utjecaj filtriranja početnih vrijednosti
for pl=1:duljina
        sinteticki(pl)=sinteticki_pros(pl+K);
end

%slijedi postavljanje početne dvije vrijednosti (prve 2 sekunde) mrežnog ispitnog zapisa na srednju vrijednost
cijelog mrežnog ispitnog zapisa kako bi se stabilizirale vrijednosti početnog kašnjenja.

for poc=1:2
   sinteticki(poc)=srednja_vrijednost;
end

end
```

Prilog P.10. Modul za obradu izlaznih podataka

```
function
[stallingDuration,meanTotalStallingDuration,K,meanStartupDelay,Nuk,Tv,BRsel,SSIMsel,R,maxBR,maxSSIM,me
anPmreze,StallNUM,meanTOTswitch,meanTotalSDmean]=DOP1v3(N_trace,V)

h = waitbar(0,'Please wait...');
count=0;
zcount=0;
flag=1;
zflag=1;
SUP=0;
SDOWN=0;
sumSUP=0;
sumSDOWN=0;
stallCounter=0;
NT=100;
C=zeros(NT,100);
ZC=zeros(NT,100);
broj=0;

for i=1:NT

[Razina,rebuffering,TDsec,network,iNuk,Nuk,To,Tv,BR,SSIM,Ruk,Psegment,Pmreze]=doprinos3_v5_s(N_trace,V)
;
   R(i,:)=Razina;
   S(i,:)=rebuffering;
   %N(i,:)=network;
   K(1,i)=TDsec;
   PM(i,:)=Pmreze;
   waitbar(i / NT);
end

%srednja propusnost mreže
meanPmreze=mean(mean(PM));

%određivanje BR za pojedinu odabranu reprezentaciju
for row=1:NT
    for col=1:Nuk
       for rep=1:Ruk
         if R(row,col)==rep
            BRsel(row,col)=BR(rep);
         end
       end
    end
end

maxBR=BR(Ruk);

%određivanje SSIM-a za pojedinu odabranu reprezentaciju
for sr=1:NT
    for sc=1:Nuk
       for reps=1:Ruk
         if R(sr,sc)==reps
            SSIMsel(sr,sc)=SSIM(reps);
         end
       end
    end
end
```

```
maxSSIM=SSIM(Ruk);

%brojanje To zastoja
for s=1:NT
   for k=1:iNuk
      if S(s,k)==1
         count=count+1;
            if zcount~=0
               ZC(s,zflag)=zcount;
               zflag=zflag+1;
               zcount=0;
            end
            if count>0 && k==iNuk
              C(s,flag)=count;
            end
      else if S(s,k)==0
         zcount=zcount+1;
            if count~=0
               C(s,flag)=count;
               flag=flag+1;
               count=0;
            end
            if zcount>0 && k==iNuk
              ZC(s,zflag)=zcount;
            end
         end
      end
   end

   zcount=0;
   count=0;
   zflag=1;
   flag=1;

end

%broj zastoja
if C(1,1)~=0
   for g=1:NT
      for u=1:100
         if C(g,u)>0
            broj=broj+1;
         else
            numberOfStalling=broj;
         end
      end
      broj=0;
   end
else
   numberOfStalling=0;
end

for a=1:NT
   for x=1:numberOfStalling
     if C(a,x)>0
        stallCounter=stallCounter+1;
     end
   end
     StallNUM(a,1)=stallCounter;
     stallCounter=0;
```

```
end
%duljina trajanja zastoja
if numberOfStalling==0
    for ut=1:NT
        for o=1:NT
            stallingDuration(o,ut)=C(o,ut)*To;
        end
    end
else
    for ut=1:numberOfStalling
        for o=1:NT
            stallingDuration(o,ut)=C(o,ut)*To;
        end
    end
end

%ukupno trajanje zastoja
if numberOfStalling==0
    stallingDurationSum=0;
else
 for u=1:NT

   stallingDurationSum(u,1)=0;

   for sd=1:numberOfStalling
   stallingDurationSum(u,1)=stallingDurationSum(u,1)+stallingDuration(u,sd);
   end
  end
end

%srednja vrijednosti trajanja zastoja
if numberOfStalling==0
    meanTotalStallingDuration=0;
else
    meanTotalStallingDuration=sum(stallingDurationSum(:,1))/100;
end

%razlika razina kvalitete dvije susjedne reprezentacije
for d=1:NT
    RD(d,:)=diff(R(d,:));
end

for p=1:NT

    %brojanje prebacivanja razina kvalitete na višu i nižu razinu
    for z=1:Nuk-1
        if RD(p,z)>0
            SUP=SUP+1;
        else if RD(p,z)<0
            SDOWN=SDOWN+1;
            end
        end
    end

    %suma dubina prebacivanja razina kvalitete na višu i nižu razinu
   for ze=1:Nuk-1
        if RD(p,ze)>0
            sumSUP=sumSUP+RD(p,ze);
        else if RD(p,ze)<0
```

```
            sumSDOWN=sumSDOWN+abs(RD(p,ze));
            end
        end
    end

    %suma za srednju vrijednost dubine prebacivanja razina kvalitete na višu
    i nižu razinu
    sumSUPvalue(p,1)=sumSUP;
    sumSDOWNvalue(p,1)=sumSDOWN;

    %ukupan broj prebacivanja razina kvalitete na višu i nižu razinu
    SWITCHUP(p,1)=SUP;
    SWITCHDOWN(p,1)=SDOWN;

    %srednja vrijednost dubine prebacivanja razina kvalitete na višu i nižu
    razinu
    meanSUPvalue(p,1)=sumSUP/SUP;
    meanSDOWNvalue(p,1)=sumSDOWN/SDOWN;

    %ukupan broj prebacivanja kvalitete
    TOTswitch(p,1)=SUP+SDOWN;

    %srednja dubina prebacivanja kvalitete
    SDmean(p,1)=(sumSUP+sumSDOWN)/(SUP+SDOWN);

    SUP=0;
    SDOWN=0;
    sumSUP=0;
    sumSDOWN=0;
end


%ukupna srednja vrijednost broja prebacivanja kvalitete
meanTOTswitch=sum(TOTswitch(:,1))/NT;

%ukupna srednja dubina prebacivanja kvalitete
meanTotalSDmean=sum(SDmean(:,1))/NT;

%prosječna razina kvalitete
for t=1:NT

    RepresentationSum(t,1)=0;

    for br=1:Nuk
            RepresentationSum(t,1)=RepresentationSum(t,1)+ R(t,br);
    end

    TotalRepresentationSum(t,1)=RepresentationSum(t,1)/Nuk;
end

%srednja prosječna razina kvalitete
meanTotalRepresentationSum=sum(TotalRepresentationSum(:,1))/NT;

%srednje prosječno početno kasnjenje
meanStartupDelay=mean(mean(K));
close(h);
end
```

Prilog P.11. Modul za analizu izlaznih podataka

```
clear all;

N_trace=17; %određivanje parametara Nakagami raspodjele vjerojatnosti iz zadanih vektora
NT=100;

[stallingDuration_S,meanTotalStallingDuration_S,K,meanStartupDelay_S
,Nuk,Tv,BRsel_S,SSIMsel_S,R_S,maxBR,maxSSIM,meanPmreze_S,StallNUM_S,meanTOTswitch_S,meanTotalS
Dmean_S]=DOP1v3(N_trace,V);

%prosječna prijenosna brzina po simulaciji za izmjereni zapis N_trace
for t=1:NT

   BRSum(t,1)=0;

   for var=2:Nuk
         BRSum(t,1)=BRSum(t,1)+ BRsel_S(t,var);
   end

   TotalBRSum_S(t,1)=BRSum(t,1)/Nuk;
end

%srednji prosječni bitrate za svih NT simulacija za izmjereni trace
meanTotalBR_S=sum(TotalBRSum_S(:,1))/NT;

%prosječni SSIM po simulaciji za izmjereni zapis N_trace
for t=1:NT

   SSIMSum(t,1)=0;

   for var=2:Nuk
   SSIMSum(t,1)=SSIMSum(t,1)+ SSIMsel_S(t,var);
   end

   TotalSSIMSum_S(t,1)=SSIMSum(t,1)/Nuk;
end

%srednji prosječni SSIM za svih NT simulacija za izmjereni trace
meanTotalSSIM_S=sum(TotalSSIMSum_S(:,1))/NT;

%srednja prosječna razina za izmjereni trace
meanRazina_S=mean(mean(R_S));

meanStallNUM_M=mean(StallNUM_M);
meanStallNUM_S=mean(StallNUM_S);

trace_sinteticki=[meanRazina_S,meanPmreze_S,meanTotalBR_S,meanTotalSSIM_S,meanTotalStallingDuration_S
,meanStallNUM_S,meanTOTswitch_S,meanTotalSDmean_S,meanStartupDelay_S];
```

Prilog P.12. EM za m=0,7 bez dodanih prekida u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]	Razlika MOS vrijedosti	**Prosječna procijenjena propusnost [kbit/s]**	**Prosječna propusnost odabrane razine [kbit/s]**	**SSIM**	**Broj prebacivanja razina kvalitete**	**Dubina prebacivanja razina kvalitete**	**Početno kašnjenje [s]**
700	1	948,9268	576,5421	0,8314	99	1,2312	0,7750
	2	913,4629	659,5109	0,8388	99	1,1606	0,7750
	3	909,7924	702,7381	0,8422	99	1,1183	0,7750
1100	1	1188,1327	736,4416	0,8429	99	1,1920	0,5200
	2	1183,1892	866,3428	0,8529	99	1,1268	0,5200
	3	1157,0065	900,0307	0,8553	99	1,1009	0,5200
1500	1	1409,1990	877,6173	0,8510	99	1,1631	0,3900
	2	1394,3793	1029,7366	0,8617	99	1,1116	0,3900
	3	1380,3047	1069,4615	0,8643	99	1,0870	0,3900
1900	1	1566,5511	892,3979	0,8509	99	1,2197	0,4700
	2	1501,7531	1049,7895	0,8611	99	1,1479	0,4700
	3	1492,4009	1131,0160	0,8656	99	1,1210	0,4700
2400	1	1768,8344	1050,6103	0,8583	99	1,1781	0,3500
	2	1753,1058	1247,1801	0,8701	99	1,1238	0,3500
	3	1717,6660	1318,3755	0,8740	99	1,1003	0,3500
2800	1	1933,9752	1152,3130	0,8626	99	1,1577	0,2850
	2	1910,6357	1371,5723	0,8751	99	1,1024	0,2850
	3	1918,5771	1467,3279	0,8797	99	1,0850	0,2850

Prilog P.13. EM za m=1 bez dodanih prekida u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]	Razlika MOS vrijedosti	**Prosječna procijenjena propusnost [kbit/s]**	**Prosječna propusnost odabrane razine [kbit/s]**	**SSIM**	**Broj prebacivanja razina kvalitete**	**Dubina prebacivanja razina kvalitete**	**Početno kašnjenje [s]**
700	1	926,5275	559,9520	0,8298	99	1,2400	0,8150
	2	890,2659	638,8317	0,8371	99	1,1560	0,8150
	3	876,3228	675,0044	0,8402	99	1,1155	0,8150
1100	1	1134,3531	710,9643	0,8414	99	1,1987	0,5450
	2	1114,8461	821,2635	0,8504	99	1,1261	0,5450
	3	1120,2090	867,7277	0,8536	99	1,0988	0,5450
1500	1	1371,0050	859,8838	0,8501	99	1,1666	0,4100
	2	1341,3619	984,4755	0,8595	99	1,1124	0,4100
	3	1331,1127	1032,1500	0,8626	99	1,0852	0,4100
1900	1	1486,9668	855,5240	0,8489	99	1,2180	0,4950
	2	1434,3779	1004,9623	0,8590	99	1,1515	0,4950
	3	1434,6477	1091,4210	0,8638	99	1,1214	0,4950
2400	1	1709,3077	1012,6461	0,8569	99	1,1808	0,3700
	2	1662,0702	1198,2775	0,8683	99	1,1178	0,3700
	3	1635,0408	1254,1425	0,8715	99	1,1019	0,3700
2800	1	1866,7569	1118,3880	0,8613	99	1,1583	0,3000
	2	1835,5679	1322,5380	0,8734	99	1,1085	0,3000
	3	1811,7023	1390,3281	0,8772	99	1,0846	0,3000

Prilog P.14. EM za m=1,3 bez dodanih prekida u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]	Razlika MOS vrijedosti	**Prosječna procijenjena propusnost [kbit/s]**	**Prosječna propusnost odabrane razine [kbit/s]**	**SSIM**	**Broj prebacivanja razina kvalitete**	**Dubina prebacivanja razina kvalitete**	**Početno kašnjenje [s]**
700	1	899,7127	538,9465	0,8280	99	1,2377	0,8350
	2	860,6185	624,7491	0,8362	99	1,1528	0,8350
	3	835,8920	645,9576	0,8378	99	1,1192	0,8350
1100	1	1123,4828	705,6005	0,8410	99	1,1977	0,5600
	2	1071,4320	792,2094	0,8486	99	1,1268	0,5600
	3	1082,5869	841,1177	0,8519	99	1,1019	0,5600
1500	1	1333,2511	837,5439	0,8489	99	1,1696	0,4200
	2	1282,2923	944,4669	0,8574	99	1,1083	0,4200
	3	1304,6978	1019,0872	0,8619	99	1,0864	0,4200
1900	1	1478,0239	828,6683	0,8474	99	1,2223	0,5100
	2	1405,8291	981,5608	0,8578	99	1,1548	0,5100
	3	1405,1260	1065,2643	0,8626	99	1,1191	0,5100
2400	1	1663,2359	978,5513	0,8554	99	1,1841	0,3800
	2	1617,4414	1158,5184	0,8667	99	1,1315	0,3800
	3	1580,2586	1216,3297	0,8701	99	1,1015	0,3800
2800	1	1787,8175	1074,7698	0,8596	99	1,1591	0,3100
	2	1763,0470	1272,5888	0,8716	99	1,1104	0,3100
	3	1751,8205	1352,0898	0,8758	99	1,0866	0,3100

Prilog P.15. EM za m=0,7 s dodanim prekidima u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]	Razlika MOS vrijedosti	Prosječna procijenjena propusnost [kbit/s]	Prosječna propusnost odabrane razine [kbit/s]	SSIM	Duljina zastoja	Broj zastoja	Broj prebacivanja razina kvalitete	Dubina prebacivanja razina kvalitete	Početno kašnjenje [s]
700	1	884,3550	486,5298	0,8175	218,7541	3,8900	90,8800	1,2778	0,7750
	2	868,5845	577,9221	0,8272	232,0868	3,6100	91,2600	1,1953	0,7750
	3	851,0491	628,6139	0,8319	223,2187	2,5800	91,9100	1,1621	0,7750
1100	1	1128,4565	604,3407	0,8258	209,3897	3,8200	91,0600	1,2561	0,5200
	2	1104,2851	746,6924	0,8390	232,7593	3,1800	91,8900	1,1836	0,5200
	3	1090,1618	803,0157	0,8441	164,5361	1,0000	92,4400	1,1450	0,5200
1500	1	1326,3174	703,7870	0,8313	209,7084	3,8600	91,2600	1,2467	0,3900
	2	1300,1971	876,7290	0,8461	233,7198	3,0700	92,2700	1,1735	0,3900
	3	1313,8956	954,6028	0,8522	209,2387	1,6700	92,6800	1,1391	0,3900
1900	1	1501,5158	704,5834	0,8309	210,2357	3,7800	91,4500	1,2950	0,4700
	2	1449,3168	921,3086	0,8470	173,7286	1,9300	91,9700	1,2090	0,4700
	3	1415,7048	1005,4304	0,8530	164,0072	1,0000	92,5700	1,1674	0,4700
2400	1	1686,8478	806,2816	0,8355	199,3307	3,4800	91,6000	1,2704	0,3500
	2	1619,3973	1043,0547	0,8528	183,8599	1,7600	92,4400	1,1967	0,3500
	3	1622,6725	1157,6712	0,8603	180,8434	1,0000	92,9000	1,1594	0,3500
2800	1	1810,3718	873,4858	0,8381	174,9059	2,8100	91,7000	1,2579	0,2850
	2	1788,5792	1140,5907	0,8567	225,9230	2,6800	92,5400	1,1867	0,2850
	3	1795,3554	1272,8941	0,8647	242,2516	2,1000	93,0600	1,1507	0,2850

Prilog P.16. EM za m=1 s dodanim prekidima u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]	Razlika MOS vrijedosti	Prosječna procijenjena propusnost [kbit/s]	Prosječna propusnost odabrane razine [kbit/s]	SSIM	Duljina zastoja	Broj zastoja	Broj prebacivanja razina kvalitete	Dubina prebacivanja razina kvalitete	Početno kašnjenje [s]
700	1	838,1635	462,3228	0,8154	216,0002	3,9500	90,7600	1,2840	0,8150
	2	818,3751	555,2898	0,8256	233,3716	3,5500	91,4400	1,1984	0,8150
	3	810,1426	600,4409	0,8298	214,3324	2,6700	91,6100	1,1597	0,8150
1100	1	1061,4828	581,5665	0,8245	211,7073	3,8500	91,0600	1,2595	0,5450
	2	1051,2925	716,1714	0,8373	230,2600	3,2300	91,7400	1,1772	0,5450
	3	1059,8696	784,0038	0,8429	153,2118	1,0000	92,2100	1,1490	0,5450
1500	1	1279,8392	683,3363	0,8303	212,4128	3,9500	91,1800	1,2415	0,4100
	2	1244,6899	845,1079	0,8446	230,5049	3,1600	91,9200	1,1703	0,4100
	3	1240,0085	907,7725	0,8499	160,9064	1,0000	92,5000	1,1417	0,4100
1900	1	1357,3597	671,0673	0,8291	212,9738	4,0600	91,1200	1,2852	0,4950
	2	1372,8913	884,0905	0,8453	235,9546	3,2300	91,9900	1,2076	0,4950
	3	1354,1752	959,8457	0,8513	247,9478	2,7100	92,6200	1,1728	0,4950
2400	1	1599,3348	779,6819	0,8343	200,7042	3,6700	91,3000	1,2649	0,3700
	2	1573,1779	1010,8709	0,8515	228,9620	2,8400	92,3100	1,1955	0,3700
	3	1562,3511	1111,8351	0,8584	179,2296	1,0000	92,8300	1,1579	0,3700
2800	1	1743,1178	850,4515	0,8373	198,4310	3,4400	91,6400	1,2505	0,3000
	2	1702,6250	1104,3334	0,8557	214,4057	2,1700	92,6600	1,1858	0,3000
	3	1681,2766	1194,8719	0,8621	194,1324	1,0000	93,1900	1,1511	0,3000

Prilog P.17. EM za m=1,3 s dodanim prekidima u reprodukciji videosignala

Srednja vrijednost propusnosti [kbit/s]	Razlika MOS vrijedosti	Prosječna procijenjena propusnost [kbit/s]	Prosječna propusnost odabrane razine [kbit/s]	SSIM	Duljina zastoja	Broj zastoja	Broj prebacivanja razina kvalitete	Dubina prebacivanja razina kvalitete	Početno kašnjenje [s]
700	1	820,4876	451,4598	0,8144	231,4421	4,4000	90,7100	1,2813	0,8350
	2	801,4548	552,5188	0,8254	203,0267	2,9000	91,3300	1,1979	0,8350
	3	807,4085	597,6573	0,8296	216,7017	2,5600	91,8400	1,1666	0,8350
1100	1	1047,9958	580,7512	0,8244	211,4353	3,7900	91,0200	1,2576	0,5600
	2	1013,1115	689,5277	0,8355	237,6273	3,6500	91,6200	1,1814	0,5600
	3	1016,1118	752,2697	0,8411	201,1593	1,7200	92,4200	1,1518	0,5600
1500	1	1234,9565	670,9492	0,8296	209,9049	3,9300	91,2100	1,2417	0,4200
	2	1200,3021	812,6377	0,8429	177,5212	1,9100	92,0400	1,1796	0,4200
	3	1212,9652	890,5478	0,8491	165,7101	1,0000	92,5500	1,1367	0,4200
1900	1	1373,8119	673,5613	0,8294	215,9238	4,1100	91,0700	1,2860	0,5100
	2	1292,9859	842,4504	0,8433	231,9661	3,1500	91,9900	1,2087	0,5100
	3	1334,6348	952,1849	0,8507	229,2451	2,1800	92,4900	1,1676	0,5100
2400	1	1545,2615	762,8910	0,8337	201,5577	3,6100	91,3800	1,2631	0,3800
	2	1514,3859	984,8041	0,8504	175,5154	1,7800	92,2300	1,2009	0,3800
	3	1517,7065	1088,9147	0,8574	167,2311	1,0000	92,7200	1,1556	0,3800
2800	1	1698,0907	838,2674	0,8370	200,8458	3,4400	91,7900	1,2541	0,3100
	2	1647,0122	1062,6430	0,8541	227,8831	2,4700	92,6800	1,1885	0,3100
	3	1678,2292	1194,0788	0,8619	232,8525	1,9600	92,9200	1,1573	0,3100