Detektiranje gubitka paketa pri prijenosu videa mrežom

Glavota, Ivan

Master's thesis / Diplomski rad

2016

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:200:050111

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2024-03-28**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

zir.nsk.hr

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA

Sveučilišni diplomski studij

DETEKTIRANJE GUBITKA PAKETA PRI PRIJENOSU VIDEA MREŽOM

Diplomski rad

Ivan Glavota

Osijek, 2016.

FERIT
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Obrazac D1: Obrazac za imenovanje Povjerenstva za obranu diplomskog rada

Osijek, 21.09.2016.

Odboru za završne i diplomske ispite

Imenovanje Povjerenstva za obranu diplomskog rada

Ime i prezime studenta:	Ivan Glavota
Studij, smjer:	Diplomski sveučilišni studij Računarstvo, smjer Procesno računarstvo
Mat. br. studenta, godina upisa:	D 727 R, 14.10.2014.
OIB studenta:	77667499660
Mentor:	Doc.dr.sc. Mario Vranješ
Sumentor:	Vukota Peković
Predsjednik Povjerenstva:	Doc.dr.sc. Marijan Herceg
Član Povjerenstva:	Doc.dr.sc. Ratko Grbić
Naslov diplomskog rada:	Detektiranje gubitka paketa pri prijenosu videa mrežom
Znanstvena grana rada:	**Programsko inženjerstvo (zn. polje računarstvo)**
Zadatak diplomskog rada:	Nekomprimirani digitalni video signali zauzimaju veliku količinu resursa pri pohrani na određeni medij i pri prijenosu mrežom. Zbog toga se prije pohrane i distribucije komprimiraju u skladu s različitim normama za kompresiju videa. Proces kompresije uvodi izobličenja u sami video i smanjuje njegovu kvalitetu. Pored toga, pri prijenosu komprimiranog videa mrežom može doći do gubitka paketa u mreži koji prenose sami video sadržaj. To dovodi do novih artefakata i dodatnog smanjenja kvalitete videa. U radu je potrebno dati pregled postojećih algoritama za detekciju artefakata nastalih zbog gubitka paketa u mreži. Nadalje, potrebno je razviti vlastiti algoritam za detekciju artefakata u videu nastalih zbog gubitka paketa pri prijenosu videa mrežom (ili unaprijediti neki već postojeći algoritam). Algoritam treba prepoznati je li se u pojedinom okviru videa dogodio gubitak paketa ili nije te pohraniti lokaciju i veličinu samog artefakta. Rezultati algoritma moraju biti dostavljeni u zadanom formatu radi prikaza u korisničkom sučelju koje ne treba biti izrađeno u sklopu ovog rada. Algoritam treba funkcionirati za video signale komprimirane u skladu s MPEG-2, H.264 i H.265 normama za razne rezolucije i brzine izmjene okvira koje se zadaju algoritmu kao ulazni parametri. (sumentor Vukota Peković)
Prijedlog ocjene pismenog dijela ispita (diplomskog rada):	Izvrstan (5)
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: 3 Postignuti rezultati u odnosu na složenost zadatka: 3 Jasnoća pismenog izražavanja: 3 Razina samostalnosti: 3
Datum prijedloga ocjene mentora:	21.09.2016.

Potpis mentora za predaju konačne verzije rada u Studentsku službu pri završetku studija:	Potpis:
	Datum:

FERIT
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA **OSIJEK**

IZJAVA O ORIGINALNOSTI RADA

Osijek, 27.09.2016.

Ime i prezime studenta:	Ivan Glavota
Studij:	Diplomski sveučilišni studij Računarstvo, smjer Procesno računarstvo
Mat. br. studenta, godina upisa:	D 727 R, 14.10.2014.
Ephorus podudaranje [%]:	3

Ovom izjavom izjavljujem da je rad pod nazivom**: Detektiranje gubitka paketa pri prijenosu videa mrežom**

izrađen pod vodstvom mentora Doc.dr.sc. Mario Vranješ

i sumentora Vukota Peković

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

Potpis studenta:

Sadržaj

1. UVOD 1
2. KOMPRESIJA VIDEA 2
2.1. MPEG-2 Part 2 3
2.2. MPEG-4 Part 10 6
2.3. MPEG-H Part 2 7
3. GUBITAK PAKETA PRI PRIJENOSU VIDEA MREŽOM 8
3.1. Klasifikacija objektivnih metoda za ocjenu kvalitete video signala 8
3.2. Klasifikacija artefakata gubitka paketa 10
3.3. Postojeći algoritmi za detekciju gubitka paketa 13
4. NOVI ALGORITAM ZA DETEKCIJU ARTEFAKTA GUBITKA PAKETA 14
4.1. Blok za predobradu 15
4.2. Blok za detekciju pravilnih pravokutnih artefakta 19
4.3. Blok za detekciju artefakta propagacije 24
4.4. Blok za naknadnu obradu 25
5. VREDNOVANJE REZULTATA NOVOG ALGORITMA ZA DETEKCIJU ARTEFAKATA GUBITKA PAKETA 29
5.1. Baza testnih signala 29
5.2. Rezultati i rasprava 31
6. ZAKLJUČAK 42
LITERATURA 43
SAŽETAK 45
ŽIVOTOPIS 46

1. UVOD

Razvoj digitalnih video tehnologija i visoko-propusnih mreža doveo je do značajnog povećanja broja multimedijskih aplikacija pruženih preko mreže. Budući da troškovi takvih aplikacija opadaju iz dana u dan, one su postale dostupne velikom broju profesionalnih, ali i neprofesionalnih korisnika. Kako bi se učinkovito pohranio i prenio video sadržaj koji je često najvažniji dio ovih aplikacija, kompresija video sadržaja je neizbježna.

Proces kompresije smanjuje prostornu i/ili vremensku zalihost nekomprimiranih video signala. Međutim, komprimirani video signali sadrže različite artefakte kompresije koji degradiraju vizualnu kvalitetu video signala. Prilikom prijenosa videa mrežom dodatna oštećenja se mogu uvesti u video signal koja nastaju kao posljedica gubitka paketa. Iako većina aplikacija i uređaja uključuju određene mehanizme za prikrivanje pogrešaka, problem smanjene kvalitete video signala kod krajnjeg korisnika nije u potpunosti riješen.

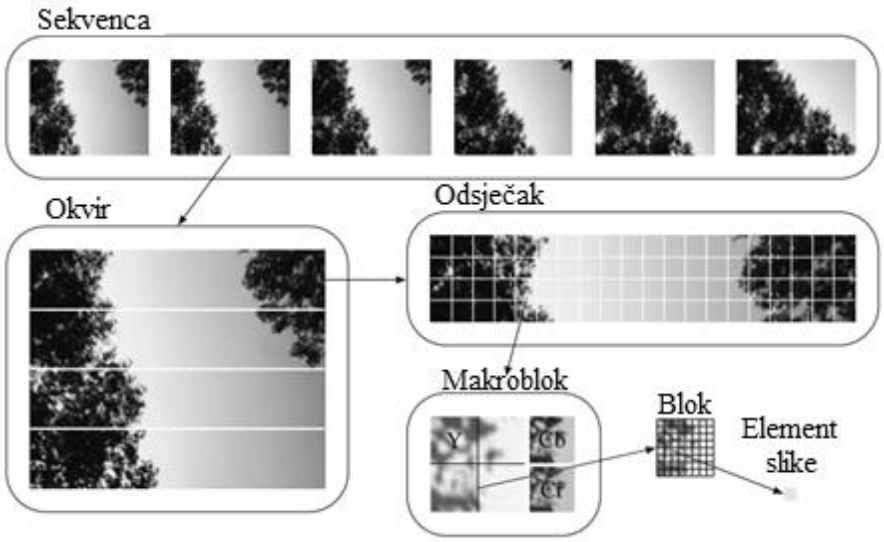
Da bi se osigurala željena kvaliteta usluge na strani krajnjeg korisnika, često je potrebno imati automatizirani sustav za mjerenje i praćenje kvalitete video signala. Jedna komponenta takvog sustava bavi se detekcijom artefakata s ciljem izolacije tih artefakta i procjene njihovog utjecaja na ukupnu opaženu kvalitetu video signala.

Rad je podijeljen na sljedeća poglavlja. U drugom poglavlju opisane su najkorištenije novije norme za kompresiju video signala. U trećem poglavlju je opisana klasifikacija objektivnih metoda za ocjenu kvalitete video signala te je opisana manifestacija i klasifikacija artefakta gubitka paketa. Zatim je dan pregled postojećih algoritama za detekciju artefakata u videu nastalih zbog gubitka paketa pri prijenosu videa mrežom. U četvrtom poglavlju predstavljen je vlastiti algoritam za detekciju gubitka paketa u video signalu bez pristupa referentnom (neoštećenom) signalu. Na kraju, u petom poglavlju dani su rezultati predstavljenog algoritma te je prikazana usporedba algoritma s postojećim algoritmima. Završno šesto poglavlje donosi zaključke rada.

2. KOMPRESIJA VIDEA

Zbog ograničenih računalnih resursa i propusnosti mreža, video signali koji se prenose ili pohranjuju podloženi su različitim stupnjevima kompresije. Najčešće korištene norme za kompresiju video signala su norme temeljene na transformaciji bloka, kao što su MPEG i H.26X. Prema [1], ovi algoritmi sažimaju veličinu video signala uklanjanjem redundancije korištenjem dvodimenzionalne transformacije, vremenskog i prostornog predviđanja te kodiranja s promjenjivom duljinom.

Prema [2], osnovna struktura video sekvence kodirane spomenutim normama organizirana je u hijerarhiji slojeva. Video sekvenca predstavlja sekvencu uzastopnih okvira. Nekolicina uzastopnih okvira mogu tvoriti skup okvira (engl. *group of pictures* - GOP). Svaki se okvir sastoji od više samostalnih odjeljaka zvanih odsječci (engl. *slices).* Nadalje, svaki odsječak sadrži niz makroblokova od koji se svaki rastavlja na pod-blokove. Svaki pod-blok se sastoji od skupa elemenata slike. Prema [2] osnovna struktura video sekvence prikazan je na slici 2.1.



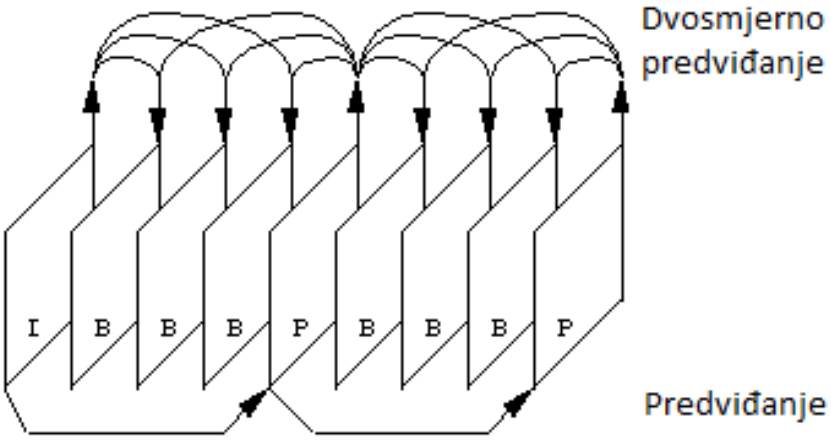
Sl. 2.1. *Osnovna struktura video sekvence MPEG i H.26X standarda [2]*

Prema [3], MPEG norme definiraju tri tipa okvira:

- I okviri (engl. *intra frame* – unutarokvirno kodirani okviri),
- P okviri (engl. *predicted frame* – predviđeni okviri),
- B okviri (engl. *bidirectional frame* – dvosmjerno predviđeni okviri).

I okviri su kodirani koristeći samo informacije prisutne u samom okviru i ta činjenica pruža mogućnost pristupa slučajnim točkama u komprimiranim video podacima. Za kompresiju I okvira koristi se samo transformacijsko kodiranje temeljeno na bloku i ona pruža umjerenu kompresiju.

P okviri su kodirani s obzirom na najbliži prethodni I ili P okvir. Ova tehnika se zove napredno predviđanje te je prikazana na slici 2.2. iz [3]. Kao i I okviri, P okviri mogu poslužiti kao referenca za predviđanje B okvira i budućih P okvira. Štoviše, P okviri koriste kompenzaciju pokreta koja pruža veći stupanj kompresije u odnosu na transformacijsko kodiranje u I okvirima.



Sl. 2.2. *Princip predviđanja okvira u MPEG normama [3]*

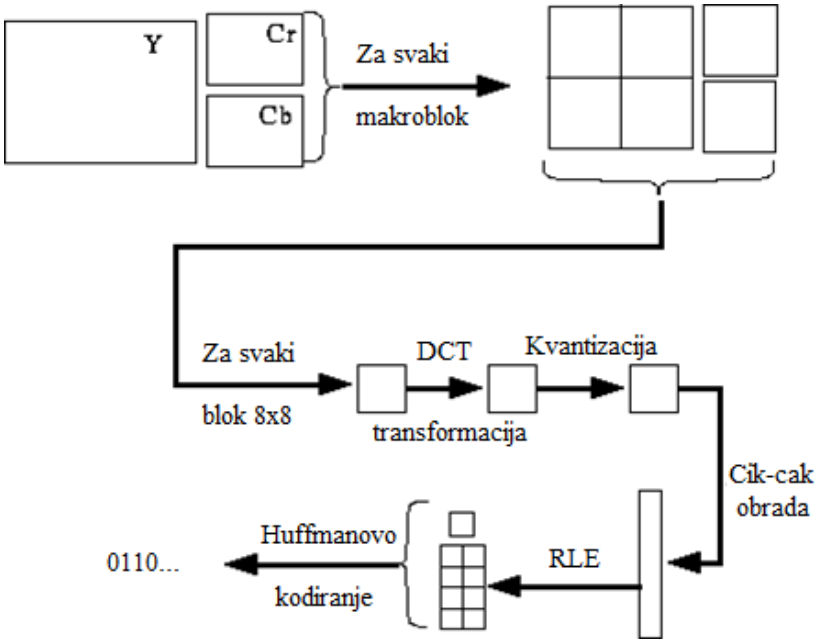
B okviri su okviri koji koriste prošle i buduće okvire kao reference. Ova tehnika se zove dvosmjerno predviđanje. B okviri pružaju najveći stupanj kompresije jer koriste prošle i buduće okvire kao reference, no njihova računalna složenost je najveća.

2.1. MPEG-2 Part 2

Osnovna norma za kompresiju video signala temeljena na transformaciji bloka jest MPEG-2 Part 2. MPEG-2 Part 2 algoritam video kompresije postiže vrlo visoke stupnjeve kompresije uklanjanjem vremenske i prostorne zalihosti koje su prisutne u pokretnom video sadržaju. Vremenska zalihost nastaje kada niz uzastopnih okvira prikazuje slični sadržaj scene. Često sadržaj scene ostaje nepromijenjen ili se neznatno mijenja između uzastopnih okvira. Prostorna zalihost nastaje preslikavanjem dijelova okvira (uz manje promjene) unutar jednog okvira videa.

Prema [3], algoritam transformacijskog kodiranja norme MPEG-2 Part 2, prikazan na slici 2.3. sadrži sljedeće osnovne korake:

- Podjela na makroblokove,
- Podjela na blokove,
- Diskretna kosinusna transformacija (engl. *discrete cosine transform* - DCT),
- Kvantizacija,
- Cik-cak obrada,
- Kodiranje slijeda istih znakova (engl. *run-length encoding* - RLE*)*,
- Kodiranje promjenjive duljine (engl. *variable-length coding* - VLC*)*.

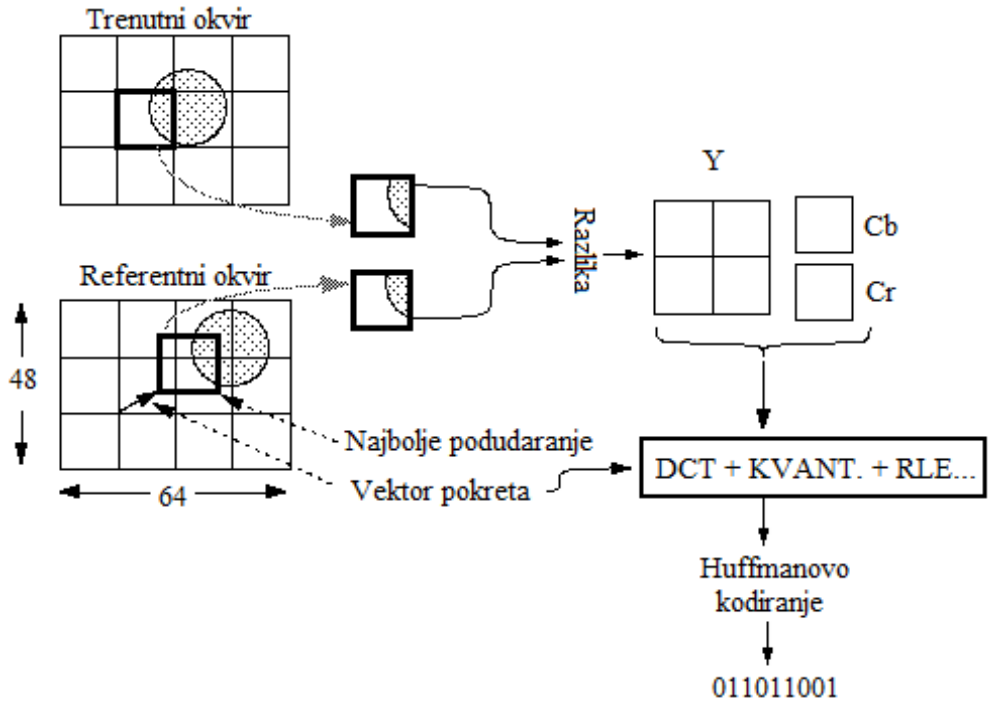


Sl. 2.3. *Postupak stvaranja I-okvira kod MPEG-2 Part 2 norme [3]*

Blokovi okvira i blokovi pogreške predviđanja imaju visoku prostornu zalihost. Kako bi se ta zalihost smanjila, algoritam norme MPEG-2 Part 2 pretvara blokove 8x8 elemenata slike iz prostorne u frekvencijsku domenu korištenjem diskretne kosinusne transformacije (DCT). Kombinacijom korištenja DCT-a i kvantizacije rezultata, mnogi frekvencijski koeficijenti su jednaki nuli, posebno koeficijenti za visoke prostorne frekvencije. Kako bi se ova činjenica u potpunosti iskoristila, koeficijenti su organizirani u cik-cak redoslijedu kako bi se proizveli dugi nizovi nula. Koeficijenti se zatim pretvaraju u niz parova, koji svaki predstavlja broj nultih koeficijenata i amplitudu koeficijenta različitog od nule. Zatim se ti parovi kodiraju pomoću koda s promjenjivom duljinom (Huffmanovo kodiranje), koji koristi kraće kodove za najčešće parove i duže kodove za manje uobičajene parove. Neki blokovi elemenata slike trebaju biti kodirani točnije od drugih. Primjerice, blokovi s glatkim intenzitetima gradijenata trebaju točnije kodiranje

kako bi se izbjegla vidljivost granica blokova. Kako bi se riješila nejednakost između blokova, algoritam u MPEG-2 normi omogućuje promjenjivu količinu kvantizacije za različite makroblokove. Ovaj mehanizam može se koristiti i za pružanje glatke adaptacije na određenoj brzini prijenosa videa mrežom.

Predviđeni okviri kodirani su u odnosu na prethodne okvire, koji su ili I ili P okviri. Prema slici 2.4. iz [3], označeni blok u trenutnom okviru sličan je referentnom, osim što je pomaknut prema gornjem desnom dijelu. Kako se većina promjena između trenutnog i referentnog okvira može aproksimirati pomoću translacije malih regija okvira, koristi se ključna tehnika nazvana predviđanje kompenzacijom pokreta.

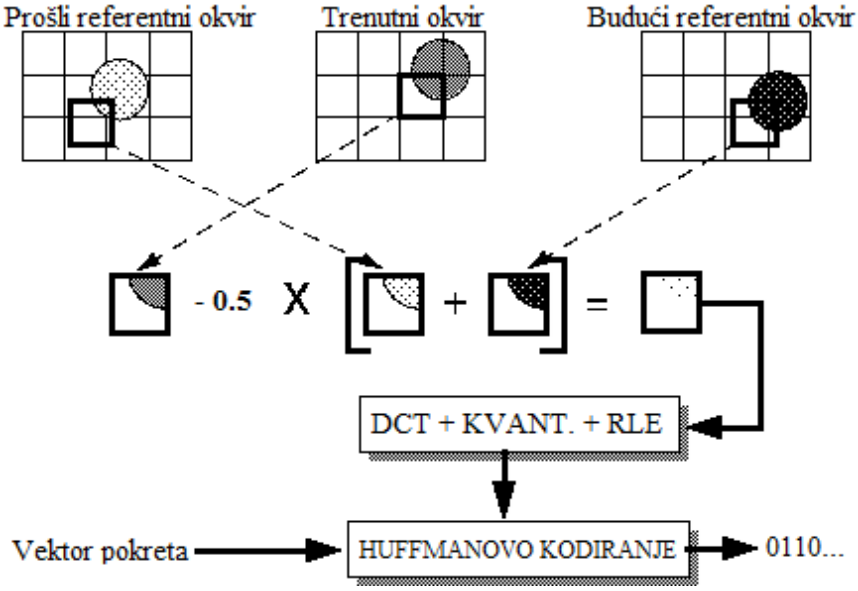


Sl. 2.4. *Postupak stvaranja P-okvira kod MPEG-2 Part 2 norme [3]*

U P-okvirima, svaki se makroblok veličine 16x16 predviđa iz makrobloka od ranije kodiranog P-okvira ili I-okvira. Kako su okviri snimke uhvaćene u određenom trenutku, makroblokovi istog sadržaja iz dva različita okvira ne moraju odgovarati istoj prostornoj lokaciji. Dakle, provodi se potraga u referentom okviru za makroblokom koji je najsličniji trenutnom obrađivanom makrobloku. Razlika između ta dva makrobloka čini rezidualni makroblok. Rezidualni okvir, okvir koji se sastoji od rezidualnih makroblokova, se može kodirati u domeni diskretne kosinusne transformacije. Primjena DCT transformacije nad rezidualnim blokovima rezultira nekolicinom visoko-frekventnih koeficijenata, koje nakon procesa kvantizacije zahtijevaju mali broj bita za

pohranu. Kvantizacijske matrice za rezidualne blokove razlikuju se od onih koji se koriste u transformacijskom kodiranju I-okvira. Pomaci u horizontalnim i vertikalnim smjerovima od najbolje podudarajućeg makrobloka iz referentnog okvira nazivaju se vektori pokreta. Diferencijalno kodiranje se koristi jer se smanjuje količina bita na način da se prenosi razlika između vektora pokreta uzastopnih okvira. Na kraju koristi se RLE i Huffmanovo kodiranje za kodiranje podataka.

Postoje neke informacije koje nisu u referentom okviru. Stoga dvosmjerno-predviđeni okviri se kodiraju kao okvir predviđanja, osim što vektor pokreta može referencirati na prethodni referentni okvir, sljedeći referentni okvir ili oboje. Mehanizam kodiranja dvosmjernih okvira prikazan je na slici 2.5. iz [3].



Sl. 2.5. *Postupak stvaranja B-okvira kod MPEG-2 Part 10 norme [3]*

Nadalje, MPEG-2 norma je dizajnirana za podršku širokom rasponu aplikacija i usluga za različite brzine prijenosa, razlučivosti i kvalitete. MPEG-2 standard definira četiri profila i četiri razine kako bi se osiguralo međusobno djelovanje tih aplikacija. Profili definiraju raspon boja i skalabilnost toka bita. Razine određuju maksimalne i minimalne vrijednosti za razlučivost slike, uzorke intenziteta svijetlosti (Y komponente) u sekundi, broj audio i video slojeva podržanih u skalabilnim profilima te maksimalnu brzinu prijenosa po profilu.

2.2. MPEG-4 Part 10

Norma MPEG-4 Part 10 (poznata i kao H.264/AVC) se temelji na istoj transformaciji bloka kao i prethodne MPEG norme. Ova norma pruža veću učinkovitost prilikom kodiranja dodavanjem

novih značajki i funkcija koje povećavaju računalnu složenost. U tablici 2.1. iz [2] prikazana je usporedba MPEG-2 Part 2 i MPEG-4 Part 10 normi.

Tab. 2.1. *Usporedba MPEG-2 Part 2 i MPEG-4 Part 10 normi za kompresiju video signala [2]*

Norma	MPEG-2 Part 2	MPEG-4 Part 10
Veličina makrobloka	16x16	16x16
Veličina bloka	8x8	16x16, 16x8, 8x16, 8x8, 4x8, 8x4, 4x4
Transformacija	8x8 DCT	8x8, 4x4 cjelobrojna transformacija
Referentni okviri	Jedan okvir	Više okvira (do 16)
Dvosmjerno predviđanje	Unaprijedna/unazadna	Unaprijedna/unazadna Unaprijedna/unaprijedna Unazadna/unazadna
Unutrašnja predikcija	Predikcija DC koeficijenata	4x4, 8x8, 16x16 prostorna
Filtar uklanjanja blokova	Nema	Ima
Ponderirana predikcija	Nema	Ima
Entropijsko kodiranje	VLC	CAVLC[1], CABAC[2]

2.3. MPEG-H Part 2

Prema [4], MPEG-H Part 2 (poznata kao H.265/HEVC) predstavlja proširenje koncepata uvedenih u MPEG-4 Part 10. Osnovne promjene norme uključuje proširenje usporedbe uzoraka i područja kodiranja od 16x16 elemenata slike do 64x64, poboljšanu segmentaciju promjenjivih veličina blokova, poboljšanu unutrašnju predikciju unutar istog okvira, poboljšanu predikciju vektora pokreta i spajanje regija pokreta, poboljšano filtriranje kompenzacije pokreta te filtriranje pomaka prilagodljivog uzorka. Dakle, makroblokovi iz prethodnih normi se zamjenjuju jedinicama kodiranog stabla (engl. *Coding tree unit* - CTU), koji mogu biti veličine 16x16, 32x32 te 64x64 elemenata slike. Učinkovito korištenje ovih poboljšanja zahtijeva mnogo više računalnih resursa za sažimanje video signala, no ima manje utjecaja na količinu izračuna potrebnog za dekompresiju.

[1] CAVLC (engl. *context-adaptive variable-length coding*)
[2] CABAC (engl. *context-adaptive binary arithmetic coding*)

3. GUBITAK PAKETA PRI PRIJENOSU VIDEA MREŽOM

Osim degradacije nastali procesom kompresije, dodatna oštećenja se mogu uvesti u video signal tijekom prijenosa preko mreže koja su uzrokovana gubitkom paketa. Prema [1], paket najčešće sadrži informacije o odsječku koji sadrži niz makroblokova te njegovim gubitkom gubi se značajan broj makroblokova koji se mogu prostirati na više redova makroblokova. Osim degradacije na okviru nastanka gubitka paketa, pogreška se može propagirati na nizu slijednih okvira do sljedećeg referentnog okvira. Prema tome, svaki paket koji se prenosi izuzetno je važan za rekonstrukciju video sadržaja.

Prema [1], gubitak paketa se najčešće detektira na transportnom sloju ili sloju sintakse videa. Zatim dekoder algoritmom za post-procesiranje najčešće pokušava prikriti degradirane makroblokove. Postupkom prikrivanja artefakta gubitka paketa pokušava se poboljšati kvaliteta slike, ali izobličenja se često ne mogu u potpunosti ukloniti.

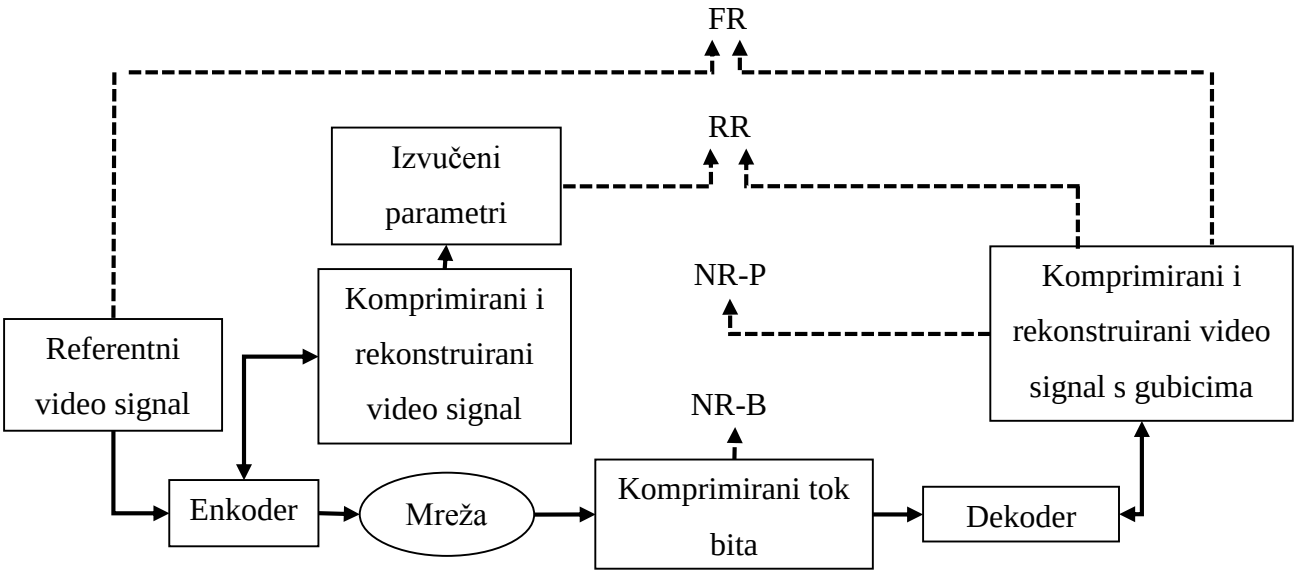
Prema [5], da bi se osigurala željena kvaliteta usluge na strani krajnjeg korisnika, često je potrebno imati automatizirani sustav za mjerenje i praćenje kvalitete video signala. Jedna komponenta takvog sustava bavi se detekcijom artefakta s ciljem izolacije tih artefakata i procjene njihovog utjecaja na ukupnu opaženu kvalitetu video signala.

3.1. Klasifikacija objektivnih metoda za ocjenu kvalitete video signala

Prema [6], ovisno o količini informacija koje su dostupne iz originalne sekvence, objektivne metode za ocjenu vizualne kvalitete se mogu podijeliti na mjere s dostupnim referentnim signalom (engl. *full reference* - FR), mjere s ograničenim informacijama o referentnom signalu (engl. *reduced reference* - RR) te mjere bez referentnog signala (engl. *no reference* - NR).

Originalna video sekvenca je dostupna u FR metodama. Prema tome, one se temelje na usporedbi izobličenog video signala s originalnim video signalom. U RR metodama nije nužno imati pristup originalnom video signalu, već je važno pružiti reprezentativne značajke o teksturi ili drugim pogodnim karakteristikama referentnog video signala. U NR metodama se ne pristupa izvornom video signalu, već se artefakti pronalaze u domeni elemenata slike (engl. *no-reference pixel-based* - NR-P), upotrebljavaju se informacije ugrađene u toku bita pripadajućeg video formata (engl. *no-reference bitstream-based* - NR-B) ili se koriste informacije sadržane u elementima slike i toku

bita (engl. *no-reference hybrid* – NR-H). Na slici 3.1. iz [7] ilustrirane su metode za ocjenu kvalitete video signala.



Sl. 3.1. *Ilustracija FR, RR i NR metoda [7]*

U posljednjih nekoliko godina, došlo je do sve većeg interesa za razvoj NR metoda zbog rasprostranjenog korištenja multimedijske usluge u kontekstu bežične komunikacije i telekomunikacijskih sustava. Prema [6], primjene NR metoda uključuju sljedeća područja:

- Mrežni operateri i davatelji usluga imaju jak interes objektivno kvantificirati stupanj kvalitete usluga isporučenih krajnjem korisniku i unutar mrežnih čvorova. NR metode pružaju podatke koji su potrebni za postavljanje mrežnih postavki pomoću kojih se osigurava zadovoljstvo krajnjeg korisnika.
- Sudjelovanje više stranaka između davatelja usluga i krajnjeg korisnika dovodi do uspostave dogovora u kojem se jamči razina kvalitete. U tom pogledu, NR metode su prikladan izbor za nadzor kvalitete u stvarnim sustavima.
- Općenito, NR metode su pogodne za obavljanje procjene kvalitete video sadržaja u stvarnom vremenu u sustavima s ograničenim resursima, kao što je frekvencijski spektar u bežičnim komunikacijama.
- Komunikacija u stvarnom vremenu i usluge reprodukcije video signala zahtijevaju prilagodbu kvalitete korištenjem NR metoda za prikupljanje statističkih podataka iz dostavljene kvalitete video signala.

3.2. Klasifikacija artefakata gubitka paketa

Prema [5], ovisno o upotrebljavanoj metodi prikrivanja degradiranih dijelova makroblokova i propagaciji te pogreške kroz niz okvira, mogu se identificirati dvije klase artefakata gubitka paketa:

- Pravilni pravokutni:
    - Neprikriveni artefakt,
    - Artefakt s niskom prostornom aktivnošću,
    - Artefakt s visokom prostornom aktivnošću,
    - Vremenski prikriveni artefakt.
- Nepravilni artefakti nastali propagacijom pogreške:
    - Artefakt propagacije.

Neprikriveni artefakt je jedan od osnovnih tipova artefakta gubitka paketa gdje dekoder ne prikriva degradaciju nastalu gubitkom paketa te su sve vrijednosti elemenata slike zahvaćenih artefaktom jednaki nuli. Neprikriveni artefakt označen s crvenim zaobljenim pravokutnikom je prikazan na slici 3.2.



Sl. 3.2. *Okvir videa s neprikrivenim artefaktom gubitka paketa*

Drugi tip artefakta u klasi pravilnih pravokutnih artefakta jest niz makroblokova s popunjenim vrijednostima elemenata slike s malom prostornom aktivnošću koja sadržajno ne pripadaju okviru. Artefakt s niskom prostornom aktivnošću označen s crvenim zaobljenim pravokutnikom je prikazan na slici 3.3.



Sl. 3.3. *Okvir videa s artefaktom niske prostorne aktivnosti kod gubitka paketa*

Treći tip artefakta u klasi pravilnih pravokutnih artefakta jest niz makroblokova koji sadrže nasumične vrijednosti elemenata slike svih komponenti video signala. Artefakt sadrži mnogo detalja i unutarnjih rubova. Artefakt s visokom prostornom aktivnošću označen s crvenim zaobljenim pravokutnikom je prikazan na slici 3.4.



Sl. 3.4. *Okvir videa s artefaktom visoke prostorne aktivnosti kod gubitka paketa*

Zadnji tip artefakta u klasi pravilnih pravokutnih artefakta jest niz makroblokova čije vrijednosti elemenata slike sadrže vrijednosti iz nekog od prethodnih okvira. Vremenski prikriveni artefakt označen s crvenim zaobljenim pravokutnikom je prikazan na slici 3.5.



Sl. 3.5. *Okvir videa s vremenski prikrivenim artefaktom kod gubitka paketa*

Artefakt propagacije reprezentira drugu klasu artefakta gubitka paketa. Artefakti propagacije nastaju propagacijom nekog od artefakata prve klase kroz nekoliko uzastopnih (predviđenih) okvira, sve dok se ne pojavi sljedeći referentni okvir. Zbog kompenzacije pokreta, artefakti prve klase mogu imati izobličene oblike te se vrijednosti elemenata slike mogu značajno promijeniti. Brzina i količina širenja najviše ovise o video sadržaju te količini kretnji kamere i objekata u području artefakta. Primjer artefakata propagacije prikazan je na slici 3.6.

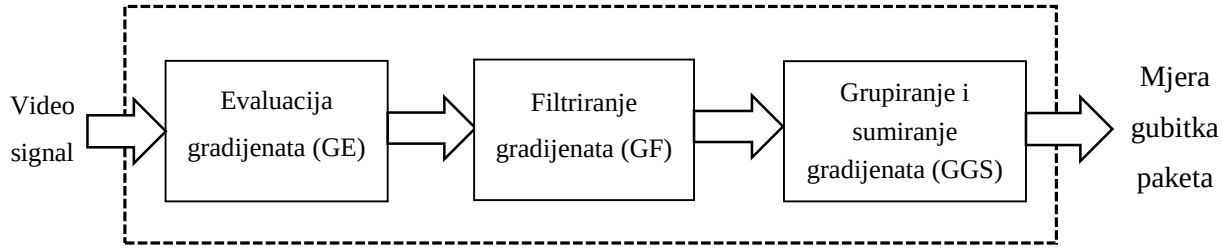


Sl. 3.6. *Okvir videa s artefaktom propagacije kod gubitka paketa*

3.3. Postojeći algoritmi za detekciju gubitka paketa

U radu [8] algoritam za detekciju gubitka paketa temelji se na dvije pretpostavke. Prvo, neoštećeni okviri imaju glatke prostorne rubove, što znači da se razlike između uzastopnih elemenata slike suviše ne razlikuju. Drugo, oštri rubovi u okviru su rijetko poravnati s granicama makrobloka. Za svaki red makrobloka, algoritam računa vertikalne gradijente na granici te iznad i ispod makrobloka kako bi se dobile tri različite matrice gradijenata. Računanjem srednje vrijednosti elemenata istog retka spomenutih matrica stvaraju se tri različita vektora gradijenata pojedinih redaka makroblokova i njihove okoline. Postojanost artefakta gubitka paketa na određenom redu makrobloka se utvrđuje velikom vrijednošću gradijenta na gornjoj granici makrobloka te izraženim diskontinuitetom gradijenata u okolini gornje i donje granice makrobloka.

Nadalje u radu [9], algoritam PLMS (engl. *packet loss measure sequence*) koristi informacije iz luminantne i krominatne komponente video signala za detekciju regija okvira koji su zahvaćeni degradacijom nastalom gubitkom paketa. Osnovni blokovski prikaz algoritma prikazan je na slici 3.7.



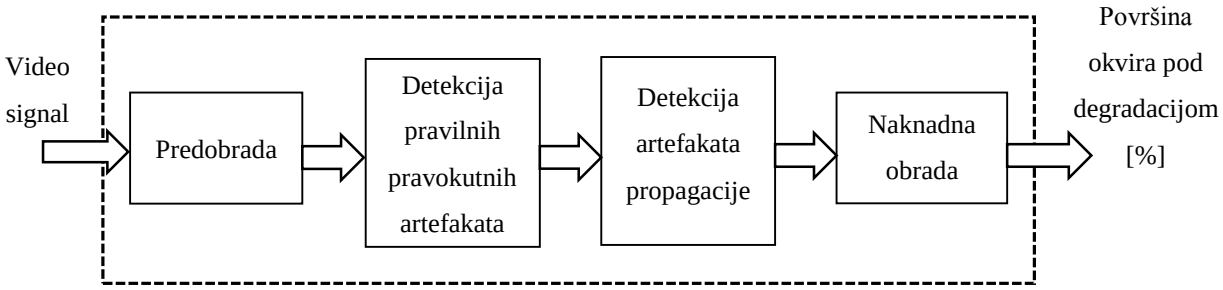
Sl. 3.7. *Blokovski prikaz PLMS algoritma [9]*

Kako se može uočiti sa slike 3.7., algoritam je razdvojen u tri serijska bloka. U bloku za evaluaciju gradijenata (engl. *gradient evaluation* - GE) vertikalni gradijenti se izračunavaju s obzirom na luminantnu i krominatnu komponentu, dok se horizontalni gradijenti računaju samo za luminantnu komponentu video signala. U bloku filtriranja gradijenata (engl. *gradient filtering* – GF), s obzirom na vertikalne gradijente, pronalaze se izraženi horizontalni rubovi s malom prostornom aktivnošću u lokalnom susjedstvu te se oni filtriraju u smjeru orijentacije ruba. Nadalje u bloku za grupiranje i sumiranje gradijenata (engl. *gradient grouping and summation* – GGS), spojeni rubovi se povezuju na određeni način unutar preklapajućih blokova, gdje je blok degradiran artefaktom gubitka paketa definiran kao blok čija je vrijednost detektiranih artefakta iznad predodređenog praga.

Postoji još radova iz ovog područja, a više o njima može se naći u [1, 10, 11, 12].

4. NOVI ALGORITAM ZA DETEKCIJU ARTEFAKTA GUBITKA PAKETA

U ovom poglavlju dan je opis novo-razvijenog algoritma za detekciju artefakta gubitka paketa. Prema [5], manje statističkih svojstava je sadržano u krominantnim komponentama video signala za različite artefakte gubitka paketa, stoga zbog potrebe izvršavanja algoritma u stvarnom vremenu u predstavljenom algoritmu korištene su informacije sadržane samo u luminantnoj komponenti video signala. Na slici 4.1. prikazan je blokovski prikaz algoritma.



Sl. 4.1. *Blokovski prikaz vlastitog algoritma za detekciju artefakata gubitka paketa*

Algoritam je podijeljen u četiri bloka povezana u seriju: blok za predobradu, blok za detekciju pravilnih artefakata, blok za detekciju propagacije pogreške i blok za naknadnu obradu. U bloku za predobradu vrši se računanje vertikalnih i horizontalnih gradijenata. Vertikalni gradijenti se filtriraju u horizontalnom smjeru nisko-propusnim filtrom. Nadalje, horizontalni i vertikalni gradijenti se dodatno filtriraju na način da se odbacuju nepovezani gradijenti te gradijenti s vrijednošću ispod predodređenog praga. U bloku za detekciju pravilnih artefakata pretražuju se izraženi upareni horizontalni rubovi koji se nalaze na granicama makrobloka. Kako bi se izbjegla detekcija neoštećenih makroblokova, dodatne značajke se uzimaju u obzir kao što su prostorna aktivnost makrobloka, postojanost vertikalnih rubova na granicama makrobloka, ponavljanje elemenata slike iz prethodnog okvira te izrazito velika promjena svih elemenata slike u odnosu na prethodni okvir. Nakon detekcije pravilnih pravokutnih artefakata, u bloku za detekciju artefakta propagacije pronalaze se artefakti propagacije na područjima makrobloka koji su u prethodnim okvirima sadržavali pravilan pravokutan artefakt gubitka paketa. Za pozitivnu detekciju traži se ili izražajni rub u okolini obrađivanog makrobloka ili vrlo mala suma apsolutnih razlika elemenata slike makrobloka trenutnog okvira i okvira nastanka pravilnog pravokutnog artefakta gubitka paketa. Nakon toga u naknadnoj obradi artefakti gubitka paketa pojedinih makroblokova istog reda se povezuju na način da se makroblokovi koji nisu detektirani u prethodnim koracima smatraju detektiranim ukoliko se oni nalaze između dva detektirana makrobloka i da je broj povezanih

neotkrivenih makroblokova manji od postavljenog praga. Osim toga, kako se artefakti mogu prostirati na više redova blokova, u bloku naknadne obrade degradirani makroblokovi koji u prethodnim koracima nisu detektirani vertikalno se povezuju. Na kraju, izlaza mjera algoritma predstavlja postotak površine okvira degradirane artefaktima gubitka paketa. Svi korišteni pragovi spomenuti prethodno ili u nastavku su određeni empirijski. Na slici 4.2. prikazan je okvir na kojemu se nalazi artefakt gubitka paketa, na kojem će se vršiti obrada u sljedećim potpoglavljima.



Sl. 4.2. *Primjer okvira videa s neprikrivenim artefaktom gubitka paketa*

4.1. Blok za predobradu

U prvom koraku korišten je visoko-propusni filtar s koeficijentima [1, -1] koji se primjenjuje na luminantnu komponentu video signala u horizontalnom i vertikalnom smjeru. Horizontalni gradijenti se računaju pomoću (4-1), dok se vertikalni gradijenti računaju pomoću (4-2).

$$\mathbf{GYH}(\mathrm{m},\mathrm{n}) = |\,\mathbf{X}(\mathrm{m},\mathrm{n}) - \mathbf{X}(\mathrm{m}-1,\mathrm{n})| \tag{4-1}$$

$$\mathbf{GYV}(\mathrm{m},\mathrm{n}) = |\,\mathbf{X}(\mathrm{m},\mathrm{n}) - \mathbf{X}(\mathrm{m},\mathrm{n}-1)| \tag{4-2}$$

gdje je:

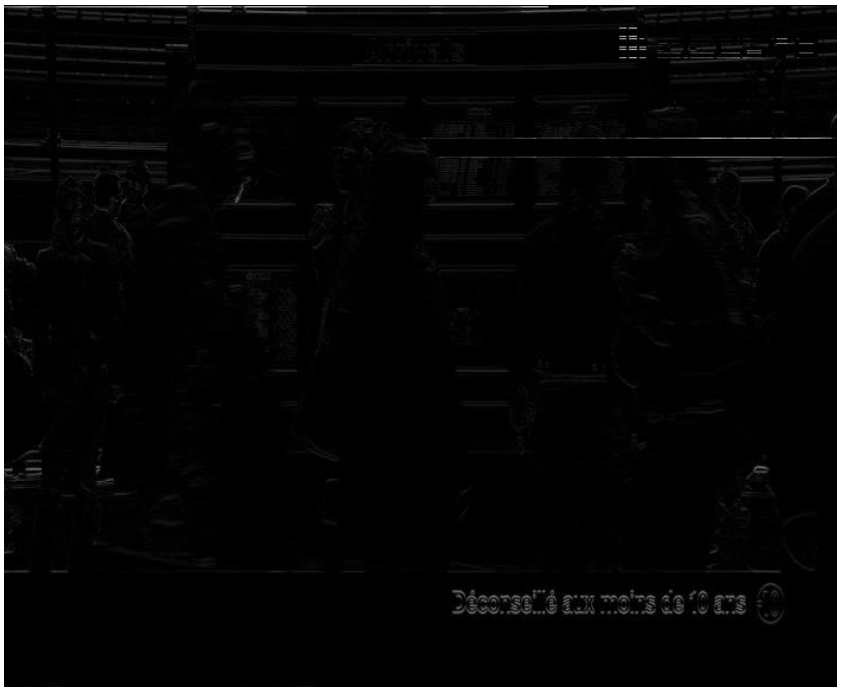
- **GYH** – matrica horizontalnih gradijenata,
- **GYV** – matrica vertikalnih gradijenata,
- **X** – matrica elemenata slike luminantne komponente,
- m – indeks stupca elementa slike,
- n – indeks retka elementa slike.

Na slici 4.3. prikazana je matrica **GYH**. Na slici su vizualizirani horizontalni gradijenti okvira sa slike 4.2.



Sl. 4.3. *Horizontalni gradijenti okvira videa sa slike 3.2.*

Na slici 4.4. vizualizirana je matrica **GYV**. Na slici su vizualizirani vertikalni gradijenti okvira sa slike 4.2.



Sl. 4.4. *Vertikalni gradijenti okvira videa sa slike 3.2.*

Zbog potrebe uklanjanja lažnih rubova, dobiveni vertikalni gradijenti se filtriraju korištenjem nisko-propusnog filtra u horizontalnom smjeru pomoću formule (4-3), čiji je rezultat ilustriran na slici 4.5.

$$\mathbf{GYVF}(\mathrm{m},\mathrm{n}) = \frac{1}{5}\sum_{i=-2}^{2} \mathbf{GYV}(\mathrm{m},\mathrm{n}-i) \tag{4-3}$$

gdje je:

- **GYVF** – matrica filtriranih vertikalnih gradijenata.



Sl. 4.5. *Vertikalni gradijenti nakon filtriranja nisko-propusnim filtrom*

Nadalje, filtrirani vertikalni gradijenti matrice **GYVF** dodatno se filtriraju u horizontalnom smjeru gdje se uklanjaju gradijenti koji su ispod predodređenog praga. Dodatno se uklanjaju gradijenti koji su kad se spoje bez prekida kraći od predodređenog praga. Dobivena matrica predstavlja matricu dodatno filtriranih vertikalnih gradijenata **GYVFF**, koja je prikazana na slici 4.6.



Sl. 4.6. *Vertikalni gradijenti nakon horizontalnog povezivanja rubova*

Matrica horizontalnih gradijenata **GYH** se također filtrira na istovjetan način, ali u vertikalnom smjeru obrađivanja i povezivanja gradijenata. Dobivena matrica predstavlja filtriranu matricu horizontalnih gradijenata **GYHF**, koja je prikazana na slici 4.7.



Sl. 4.7. *Horizontalni gradijenti nakon vertikalnog povezivanja rubova*

4.2. Blok za detekciju pravilnih pravokutnih artefakta

U ovome bloku obrada se vrši na razini makrobloka. Prvenstveno se traže izraženi upareni horizontalni rubovi koji se nalaze na granicama makrobloka te koji u svojoj lokalnoj okolini imaju malu prostornu aktivnost gradijenata, vertikalne rubove na granicama makrobloka, elemente slika makrobloka koji se ponavljaju ili koji su se značajno promijenili u odnosu na prethodni okvir. Srednja vrijednost vertikalnih gradijenata na gornjoj granici makrobloka se računa pomoću formule (4-5), dok se srednja vrijednost za donju granicu makrobloka računa pomoću formule (4-6).

$$\mathbf{TEG}(\mathrm{x},\mathrm{y}) = \frac{1}{16}\sum_{i=1}^{16} \mathbf{GYVFF}(\mathrm{m}+i,\mathrm{n}) \tag{4-5}$$

$$\mathbf{BEG}(\mathrm{x},\mathrm{y}) = \frac{1}{16}\sum_{i=1}^{16} \mathbf{GYVFF}(\mathrm{m}+i,\mathrm{n}+16) \tag{4-6}$$

gdje je:

- **TEG** – matrica srednjih vrijednosti gradijenata na gornjoj granici makrobloka,
- **BEG** – matrica srednjih vrijednosti gradijenata na donjoj granici makrobloka,
- x – indeks stupca makrobloka,
- y – indeks retka makrobloka.

Kako bi se izračunao mogući diskontinuitet gradijenata uzrokovan gubitkom paketa, računaju se srednje vrijednosti vertikalnih gradijenata u okolini granice makrobloka prikazano formulama (4-7), (4-8), (4-9) i (4-10).

$$\mathbf{TEGA}(\mathrm{x},\mathrm{y}) = \frac{1}{16}\sum_{i=1}^{16} \mathbf{GYV}(\mathrm{m}+i,\mathrm{n}-1) \tag{4-7}$$

$$\mathbf{TEGB}(\mathrm{x},\mathrm{y}) = \frac{1}{16}\sum_{i=1}^{16} \mathbf{GYV}(\mathrm{m}+i,\mathrm{n}+1) \tag{4-8}$$

$$\mathbf{BEGA}(\mathrm{x},\mathrm{y}) = \frac{1}{16}\sum_{i=1}^{16} \mathbf{GYV}(\mathrm{m}+i,\mathrm{n}+15) \tag{4-9}$$

$$\mathbf{BEGB}(\mathrm{x},\mathrm{y}) = \frac{1}{16}\sum_{i=1}^{16} \mathbf{GYV}(\mathrm{m}+i,\mathrm{n}+17) \tag{4-10}$$

gdje je:

- **TEGA** – matrica srednjih vrijednosti vertikalnih gradijenata iznad gornje granice makrobloka,
- **TEGB** – matrica srednjih vrijednosti vertikalnih gradijenata ispod gornje granice makrobloka,
- **BEGA** – matrica srednjih vrijednosti vertikalnih gradijenata iznad donje granice makrobloka,
- **BEGB** – matrica srednjih vrijednosti vertikalnih gradijenata ispod donje granice makrobloka.

Postojanost izraženog ruba nastalog artefaktom gubitka paketa se utvrđuje pomoću uvjeta danoj u formuli (4-11) za gornji horizontalni rub, a u formuli (4-12) za donji horizontalni rub.

$$\mathbf{TEG}(\mathrm{x},\mathrm{y}) > \mathrm{The}\ \&\&\ \mathbf{TEG}(\mathrm{x},\mathrm{y}) > \max\left(\mathbf{TEGA}(\mathrm{x},\mathrm{y}), \mathbf{TEGB}(\mathrm{x},\mathrm{y})\right) \ \&\&\ \mathrm{Ntep} > \mathrm{Thpc} \tag{4-11}$$

$$\mathbf{BEG}(\mathrm{x},\mathrm{y}) > \mathrm{The}\ \&\&\ \mathbf{BEG}(\mathrm{x},\mathrm{y}) > \max\left(\mathbf{BEGA}(\mathrm{x},\mathrm{y}), \mathbf{BEGB}(\mathrm{x},\mathrm{y})\right) \ \&\&\ \mathrm{Nbep} > \mathrm{Thpc} \tag{4-12}$$

gdje je:

- The – dinamički prag degradacije vertikalnog ruba,
- Thpc – dinamički prag broja elemenata slike pod degradacijom gubitka paketa,
- Ntep – broj gradijenata iz matrice **TEG** koji su iznad praga The,
- Nbep – broj gradijenata iz matrice **BEG** koji su iznad praga The.

Osim vertikalnih gradijenata, za poboljšanu detekciju artefakta koriste se informacije sadržane u horizontalnim gradijentima. U formuli (4-13) dano je računanje srednje vrijednosti gradijenata na lijevoj granici makrobloka, dok u formuli (4-14) dano je računanje srednje vrijednosti gradijenata na desnoj granici makrobloka.

$$\mathbf{LEG}(\mathrm{x},\mathrm{y}) = \frac{1}{16}\sum_{i=1}^{16} \mathbf{GYHF}(\mathrm{m},\mathrm{n}+i) \tag{4-13}$$

$$\mathbf{REG}(\mathrm{x},\mathrm{y}) = \frac{1}{16}\sum_{i=1}^{16} \mathbf{GYHF}(\mathrm{m}+16,\mathrm{n}+i) \tag{4-14}$$

gdje je:

- **LEG** – matrica srednjih vrijednosti gradijenata na lijevoj granici makrobloka,
- **REG** – matrica srednjih vrijednosti gradijenata na desnoj granici makrobloka.

Kao kod vertikalnih gradijenata, računaju se srednje vrijednosti horizontalnih gradijenata u okolini granice makrobloka prikazano formulama (4-15), (4-16), (4-17) i (4-18).

$$\mathbf{LEGA}(x,y) = \frac{1}{16}\sum_{i=1}^{16} \mathbf{GYH}(m-1, n+i) \tag{4-15}$$

$$\mathbf{LEGB}(x,y) = \frac{1}{16}\sum_{i=1}^{16} \mathbf{GYH}(m+1, n+i) \tag{4-16}$$

$$\mathbf{REGA}(x,y) = \frac{1}{16}\sum_{i=1}^{16} \mathbf{GYH}(m+15, n+i) \tag{4-17}$$

$$\mathbf{REGB}(x,y) = \frac{1}{16}\sum_{i=1}^{16} \mathbf{GYH}(m+17, n+i) \tag{4-18}$$

gdje je:

- **LEGA** – matrica srednjih vrijednosti horizontalnih gradijenata lijevo od lijeve granice makrobloka,
- **LEGB** – matrica srednjih vrijednosti horizontalnih gradijenata desno od lijeve granice makrobloka,
- **REGA** – matrica srednjih vrijednosti horizontalnih gradijenata lijevo od desne granice makrobloka,
- **REGB** – matrica srednjih vrijednosti horizontalnih gradijenata desno od desne granice makrobloka.

Postojanost izraženog ruba nastalog artefaktom gubitka paketa se utvrđuje se pomoću uvjeta danoj u formuli (4-19) za gornji horizontalni rub, a u formuli (4-20) za donji horizontalni rub.

$$\mathbf{LEG}(\mathrm{x},\mathrm{y}) > \mathrm{Tve}\ \&\&\ \mathbf{LEG}(\mathrm{x},\mathrm{y}) > \max\big(\mathbf{LEGA}(\mathrm{x},\mathrm{y}), \mathbf{LEGB}(\mathrm{x},\mathrm{y})\big) \ \&\&\ \mathrm{Nlep} > \mathrm{Tvpc} \tag{4-19}$$

$$\mathbf{REG}(\mathrm{x},\mathrm{y}) > \mathrm{Tve}\ \&\&\ \mathbf{REG}(\mathrm{x},\mathrm{y}) > \max\big(\mathbf{REGA}(\mathrm{x},\mathrm{y}), \mathbf{REGB}(\mathrm{x},\mathrm{y})\big) \ \&\&\ \mathrm{Nrep} > \mathrm{Tvpc} \tag{4-20}$$

gdje je:

- Tve – dinamički prag degradacije horizontalnog ruba,
- Tvpc – dinamički prag broja elemenata slike pod degradacijom gubitka paketa,
- Nlep – broj gradijenata iz matrice **LEG** koji su iznad praga vet,
- Nrep – broj gradijenata iz matrice **REG** koji su iznad praga vet.

Kako bi se izbjegla detekcija neoštećenih makroblokova, dodatne značajke se uzimaju u obzir kao što su prostorna aktivnost makrobloka, postojanost vertikalnih rubova na granicama makrobloka, ponavljanje elemenata slike iz prethodnog okvira te ogromna promjena svih elemenata slike u odnosu na prethodni okvir. Računanje prostorne aktivnosti makroblokova dano je u formuli (4-21).

$$\mathbf{SA}(\mathrm{x},\mathrm{y}) = \sum_{i=1}^{16}\sum_{j=1}^{16}\sqrt{\mathbf{GYH}(\mathrm{m}+j,\mathrm{n}+i)^2 + \mathbf{GYV}(\mathrm{m}+j,\mathrm{n}+i)^2} \tag{4-21}$$

gdje je:

- **SA** – matrica prostornih aktivnosti makroblokova.

Postojanost male prostorne aktivnost se utvrđuje ukoliko je vrijednost prostorne aktivnosti ispod predodređenog praga. Nadalje u formuli (4-22) dano je računanje ponavljanja elemenata slike iz prethodnog okvira.

$$\mathbf{FD}(\mathrm{x},\mathrm{y}) = \sum_{i=1}^{16}\sum_{j=1}^{16}|\boldsymbol{X}(\mathrm{m}+j,\mathrm{n}+i) - \boldsymbol{X1}(\mathrm{m}+j,\mathrm{n}+i)| \tag{4-22}$$

gdje je:

- **FD** – matrica suma apsolutnih razlika trenutnog i prethodnog okvira,
- **X1** – matrica elemenata slike luminantne komponente prethodnog okvira.

Male promjene u svjetlini se utvrđuju ukoliko je suma iz matrice **FD** ispod predodređenog praga. Ukoliko je suma iz matrice **FD** iznad drugog predodređenog praga, utvrđuje se golema promjena između trenutnog i prethodnog okvira.

Nadalje, kako bi se utvrdila degradiranost makrobloka uzrokovana gubitkom paketa, potrebna je provjera niza uvjeta koji karakteriziraju artefakte gubitka paketa. U formuli (4-23) dan je uvjet koji utvrđuje postojanost artefakta gubitka paketa na trenutno obrađivanom makrobloku.

$$TES \;\&\&\; BES \;\&\&\; (SAMS \;||\; (LES \;||\; RES) \;\&\&\; MMCS \;||\; LES \;\&\&\; RES \;||\; MEDS \;\&\&\; MDS) \tag{4-23}$$

gdje je:

- TES – zastavica postojanosti degradiranog ruba na gornjoj granici makrobloka,
- BES – zastavica postojanosti degradiranog ruba na donjoj granici makrobloka,
- SAMS – zastavica postojanosti male prostorne aktivnosti unutar makrobloka,
- LES – zastavica postojanosti degradiranog ruba na lijevoj granici makrobloka,
- RES – zastavica postojanosti degradiranog ruba na desnoj granici makrobloka,
- MMCS – zastavica postojanosti velike promjene elemenata slike makrobloka između trenutnog i prethodnog okvira,
- MEDS – zastavica postojanosti izraženog ruba,
- MDS – zastavica postojanosti prethodno detektiranih makroblokova unutar istog reda.

Na slici 4.8 prikazan je okvir sa slike 4.2. s detektiranim pravilnim, pravokutnim artefaktima gubitka paketa na razini makrobloka koji su označeni crvenim pravokutnicima.



Sl. 4.8. *Detektirani pravilni, pravokutni artefakti gubitka paketa*

4.3. Blok za detekciju artefakta propagacije

U ovome dijelu algoritma pronalaze se artefakti propagacije na područjima makrobloka koji su u prethodnim okvirima sadržavali pravilan pravokutan artefakt gubitka paketa. Za pozitivnu detekciju traži se ili izražajni rub u okolini obrađivanog makrobloka ili vrlo mala suma razlika elemenata slike makrobloka trenutnog okvira i okvira nastanka pravilnog pravokutnog artefakta gubitka paketa. Na slici 4.9. prikazan je okvir koji slijedi nakon okvira sa slike 4.2. Prikazani okvir sadrži artefakt propagacije.



Sl. 4.9. *Okvir s artefaktom propagacije*

Za svaki prethodno detektirani makroblok koji u trenutnom okviru ne sadrži pravilni pravokutni artefakt gubitka paketa, vrši se pretraga izraženog ruba. Pretraga se vrši na način da se za svaki red matrice **GHY** u okolini i unutar makrobloka sumiraju vrijednosti filtriranih vertikalnih gradijenata. Ukoliko je suma gradijenata reda makrobloka iznad predodređenog praga, tada se utvrđuje postojanost artefakta propagacije unutar obrađivanog makrobloka.

Nadalje, prilikom propagacije degradacije nastale gubitkom paketa može doći do izobličenja karakterističnih rubova artefakta. U tom slučaju, kod malih pokreta kamere ili objekata u sceni, vrijednosti sadržane unutar makrobloka koji sadrži artefakt propagacije gubitka paketa se neznatno razlikuju kroz nekoliko sljedećih okvira video signala. Stoga se prilikom detekcije pravilnih pravokutnih artefakta gubitka paketa spremaju vrijednosti elemenata slike makroblokova te se prilikom provjere prema formuli (4-24) utvrđuje suma apsolutnih razlika elemenata slike

makrobloka trenutno obrađivanog okvira i makrobloka prvobitno detektiranog pravilnog pravokutnog artefakta gubitka paketa.

$$\mathbf{BD}(\mathrm{x},\mathrm{y}) = \sum_{i=1}^{16}\sum_{j=1}^{16} |\boldsymbol{X}(\mathrm{m}+j,\mathrm{n}+i) - \boldsymbol{XM}(j,i)| \tag{4-24}$$

gdje je:

- **BD** – matrica suma apsolutnih razlika elemenata slike,
- **X** – matrica trenutno obrađivanog okvira,
- **XM** – matrica elemenata slike prethodno detektiranog makrobloka.

Ukoliko je suma apsolutnih razlika manja od predodređenog praga, tada se utvrđuje postojanost artefakta propagacije unutar obrađivanog makrobloka. Pretraga karakteristika propagacije na područjima prethodne detekcije artefakta propagacije se prekida nakon Npaf okvira. Na slici 4.10. prikazani su detektirani artefakti gubitka paketa. Crvenom bojom označeni su pravilni, pravokutni artefakt gubitka paketa, dok su zelenom bojom označeni makroblokovi koji sadrže artefakte propagacije.



Sl. 4.10. *Detektirani artefakti gubitka paketa sa slike 4.9.*

4.4. Blok za naknadnu obradu

Kako se zbog djelomičnog prikrivanja sa izvornim sadržajem te propagacijom pogreške kroz niz okvira uklanjaju karakteristike artefakta gubitka paketa, za poboljšanu detekciju artefakti makrobloka se horizontalno povezuju na način da se makroblokovi koji nisu detektirani smatraju

detektiranim ukoliko se oni nalaze između dva detektirana makrobloka u istom redu i da je broj povezanih neotkrivenih makroblokova u istom redu manji od postavljenog praga. Na slici 4.11. nalazi se okvir s vremenski prikrivenim artefaktom koji se djelomično prikriva sa svojom okolinom. Na slici 4.12. crvenim pravokutnicima označeni su detektirani pravilni, pravokutni artefakti gubitka paketa, dok su bijelim pravokutnicima označeni makroblokovi koji su detektirani nakon postupka horizontalnog spajanja makroblokova.



Sl. 4.11. *Okvir videa s vremenski prikrivenim artefaktom gubitka paketa*



Sl. 4.12. *Vertikalno povezivanje makroblokova koji sadrže artefakt gubitka paketa*

Nadalje, kako bi se detektirali artefakti koji se protežu na više redova makroblokova, makroblokovi se vertikalno povezuju ukoliko gornji makroblok ima detektirani degradirani rub na gornjoj granici makrobloka, donji makroblok ima detektirani degradirani rub na donjoj granici makrobloka te su prostorne aktivnosti makroblokova između gornjeg i donjeg makrobloka ispod predodređenog praga. Na slici 4.13. prikazan je artefakt gubitka paketa koji se proteže na više redova makroblokova. Na slici 4.14. žutom bojom označeni su vertikalno povezani makroblokovi koji sadrže artefakt gubitka paketa, dok su crvenom bojom označeni pravilni, pravokutni artefakti gubitka paketa na razini makrobloka.



Sl. 4.13. *Okvir s neprekrivenim artefaktom gubitka paketa koji se proteže na više redova makroblokova*



Sl. 4.14. *Vertikalno povezivanje makroblokova koji sadrže artefakt gubitka paketa*

Na kraju, prema formuli (4-25), brojevi detektiranih degradiranih makroblokova iz bloka za detekciju pravilnih pravokutnih artefakata, bloka za detekciju artefakta propagacije i bloka naknada obrade se sumiraju i dijele s ukupnim brojem makroblokova okvira, čime se dobiva ukupna površina okvira koja sadrži artefakte gubitka paketa, što predstavlja izlaznu mjeru algoritma.

$$\mathrm{PLAM} = \frac{\mathrm{Nram} + \mathrm{Npam} + \mathrm{Nvaam} + \mathrm{Nhaam}}{\mathrm{Nfm}} * 100 \tag{4-25}$$

gdje je:

- PLAM – postotak površine okvira koja sadrži artefakte gubitka paketa,
- Nram – broj detektiranih makroblokova pravilnih pravokutnih artefakata gubitka paketa,
- Npam – broj detektiranih makroblokova artefakata propagacije gubitka paketa,
- Nvaam – broj detektiranih makroblokova nakon vertikalnog povezivanja artefakata gubitka paketa,
- Nhaam – broj detektiranih makroblokova nakon horizontalnog povezivanja artefakata gubitka paketa,
- Nfm – ukupan broj makroblokova okvira.

5. VREDNOVANJE REZULTATA NOVOG ALGORITMA ZA DETEKCIJU ARTEFAKATA GUBITKA PAKETA

U ovome poglavlju dan je pregled baze testnih signala korištenih u analizi rada razvijenog algoritma za detekciju artefakta gubitka paketa. Zatim su dani i uspoređeni rezultati novo-predstavljenog i postojećih algoritama.

5.1. Baza testnih signala

Rezultati predstavljenog i postojećih algoritama za detekciju artefakata gubitka paketa dani su za nekoliko video sekvenci standardne razlučivosti (engl. *standard-definition* – SD) u progresivnom formatu korištenih u radu [9]. Video signali s tri različita sadržaja su degradirani uz pet razina degradacije. U prvoj degradacijskoj razini, na svakih sto tisuća bitova jedan bit se postavio na nulu. Nadalje, u drugoj razini degradacije, dva bita su degradirana, u trećoj razini četiri bita, u četvrtoj razini osam bita te u petoj razini šesnaest bita. Kako bi se osigurali pouzdani rezultati, svaka degradirana video sekvenca je generirana tri puta, što osigurava pojavu artefakata gubitka paketa na različitim područjima okvira. Ova će se baza u nastavku rada zvati PLGID (engl. *packet loss gradually increased database*) i sadrži ukupno 45 degradiranih sekvenci.

Osim toga, iz baze video signala tvrtke RT-RK [13] dobavljene su video sekvence za testiranje ispravnosti rada algoritma za detekciju gubitka paketa. Sekvence su prirodnog i umjetnog sadržaja. Ova će se baza u nastavku rada zvati RT-RKD (engl. RT-RK *Database*) i sadrži 2 degradirane sekvence. Video sekvenca s umjetnim sadržajem sadrži računalnu pozadinu s trakom izbornika, ikonama i pokrenutim programom za reprodukciju video signala s videom prirodnog sadržaja. Ova sekvenca nije degradirana artefaktima gubitka paketa. Okvir video sekvence s umjetnim sadržajem prikazan je na slici 5.1. Drugi sadržaj predstavlja video sekvenca s nadzorne kamere koja snima promet autoceste. Video sekvenca spomenutog sadržaja sadrži informacije i vizualizacije koje su sličnog pravokutnog oblika kao što su artefakti gubitka paketa. Ova sekvenca nije degradirana artefaktima gubitka paketa. Na slici 5.2. prikazan je okvir bez degradacije artefaktima gubitka paketa video sekvence s autocestom.



Sl. 5.1. *Okvir video sekvence s umjetnim sadržajem bez gubitka paketa*



Sl. 5.2. *Okvir video sekvence s autocestom bez gubitka paketa*

Na kraju, kako je iznos degradirane površine okvira zbog gubitka paketa uglavnom nepoznat, u sklopu ovog diplomskog rada generirane su video sekvence s umjetno stvorenim artefaktima gubitka paketa. Generirano je dvadeset video sekvenci s pet različitih sadržaja, tri različite rezolucije i četiri degradacijske razine. U prvoj degradacijskoj razini u video sekvencu su umetnuti artefakti koji zauzimaju od dva do pet posto ukupne površine okvira, u drugoj razini između pet i

deset posto, u trećoj između deset i pedeset posto, dok je u zadnjoj degradacijskoj razini više od pedeset posto ukupne površine video okvira degradirano. Izvorne video sekvence preuzete su iz [14]. Opće informacije o izvornim video sekvencama nalaze se u tablici 5.1. Nad svakom sekvencom nasumično su umetnute tri različite klase artefakta. Prva klasa umetnutih artefakata predstavlja neprikriveni artefakt čija vrijednost svih elemenata slike unutar obuhvaćenih makroblokova je jednaka nuli. U drugoj klasi artefakata svi elementi slike zahvaćeni artefaktom poprimaju istu vrijednost koja predstavlja srednju vrijednost elemenata slike područja okvira oko onoga gdje se artefakt postavlja. Na kraju, u trećoj klasi artefakata svaki element slike pojedinog makrobloka umetnutog artefakta poprima srednju vrijednost elemenata slike područja postavljanja odgovarajućeg makrobloka artefakta. Ova će se baza u nastavku rada zvati GRD (engl. *generated referent database*) i sadrži ukupno 20 sekvenci.

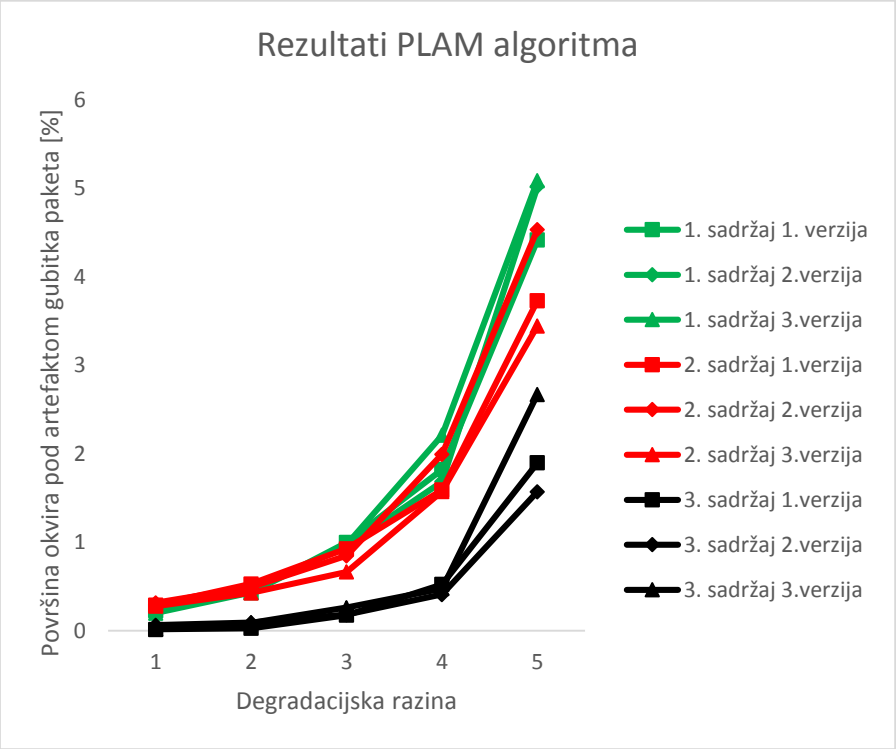
Tab. 5.1. *Opće informacije o izvornim video sekvencama korištenim prilikom stvaranja generiranih video sekvenci iz GRD baze podataka*

Ime video sekvence	Rezolucija okvira	Ukupan broj okvira
Obiteljska proslava	720x576	400
Kristen i Sara	1280x720	500
Pješačka zona	1920x1080	300
Željeznička pruga	1920x1080	300
Pčela	1920x1080	500

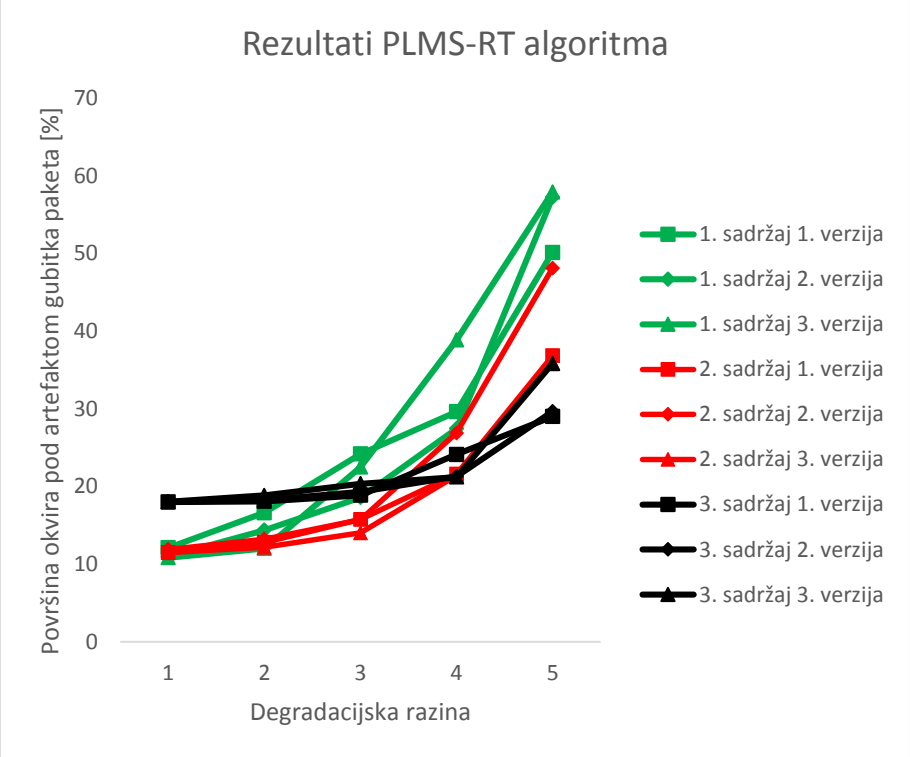
5.2. Rezultati i rasprava

Zbog potrebe usporedbe algoritma s postojećim rješenjima, dobavljena je prilagođena verzija algoritma PLMS iz rada [9] od tvrtke Institut RT-RK Osijek. Prilagođeni algoritam PLMS-RT (engl. *packet loss measure sequence – real-time*) predstavlja pojednostavljenu verziju PLMS algoritma koja je u mogućnosti vršiti obradu u stvarnom vremenu. Izlazna vrijednost PLMS-RT algoritma predstavlja nelinearnu mjeru degradiranosti rubova čija je maksimalna vrijednost deset tisuća. Kako bi se izvršila usporedba s predstavljenim algoritmom, izlazna se mjera dijeli s maksimalnom vrijednošću PLMS-RT algoritma te množi sa sto kako bi se dobili rezultati u postotcima. Svi rezultati u ovome poglavlju su dobiveni iz jednog skupa zadanih parametara pragova.

U nastavku rada predstavljeni algoritam će se označavati kraticom PLAM (engl. *packet loss area measure*). Pokretanjem PLAM algoritma nad sekvencama iz PLGID baze dobiveni su rezultati prikazani na slici 5.3., dok su rezultati algoritma PLMS-RT prikazani na slici 5.4.



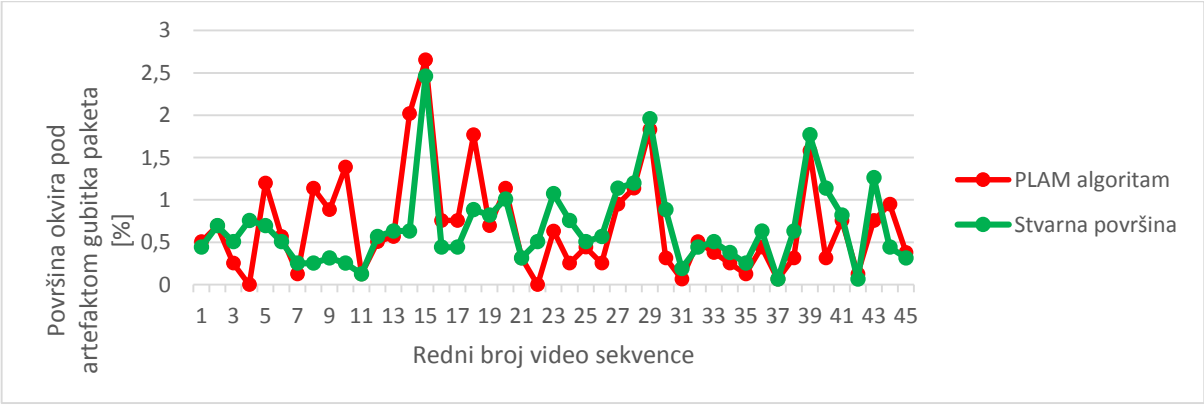
Sl. 5.3. *Rezultati PLAM algoritma za sekvence iz PLGID baze*



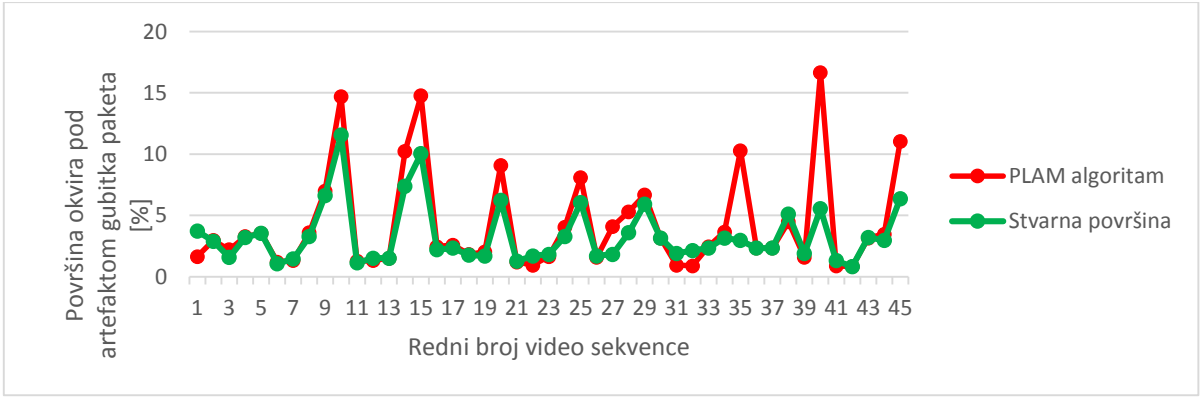
Sl. 5.4. *Rezultati PLMS-RT algoritma za sekvence iz PLGID baze*

Rezultat svake degradacijske razine, sadržaja i verzije predstavlja srednju vrijednost rezultata algoritama PLAM i PLMS-RT svih okvira pojedinih sekvenci. Povećavanjem degradacijske razine, rezultati algoritama postupno se povećavaju. Treba primijetiti da PLMS-RT algoritam pokazuje konzistentno da je veća površina okvira pod artefaktom nego što to pokazuje PLAM algoritam. Obično gledatelj vrlo će lako gledajući sekvencu doći do zaključka da PLMS-RT znatno precjenjuje stvarnu količinu artefakta.

Kako bi se odredilo odstupanje rezultata algoritma od stvarne vrijednosti degradacije koja se nalazi na okviru, za svaku video sekvencu iz PLGID baze odabrana su dva slučajna okvira na kojemu se nalaze mali, odnosno veliki broj degradiranih makroblokova. Na okvirima se nalaze artefakti različitih klasa i vrsta te različitih prikrivenosti s okolinom. Artefakti na odabranim okvirima video sekvenci su se ručno prebrojali. Na slici 5.5. nalazi se graf na kojemu je prikazan rezultat PLAM algoritma za detekciju gubitka paketa te stvaran iznos degradacije koja se nalazi na okviru s malim brojem artefakta, dok na slici 5.6. prikazan je graf za okvire s većim brojem artefakata.



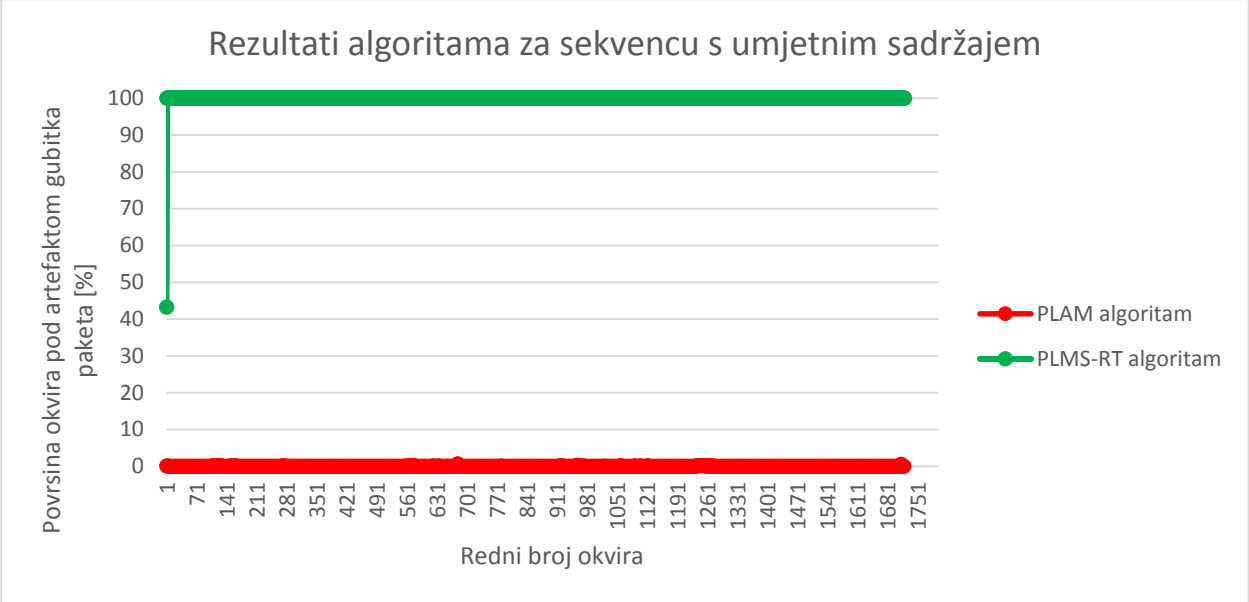
Sl. 5.5. *Odstupanje rezultata PLAM algoritma od stvarnih rezultata za slučajno odabrane okvire s malom količinom artefakata za sekvence iz PLGID baze*



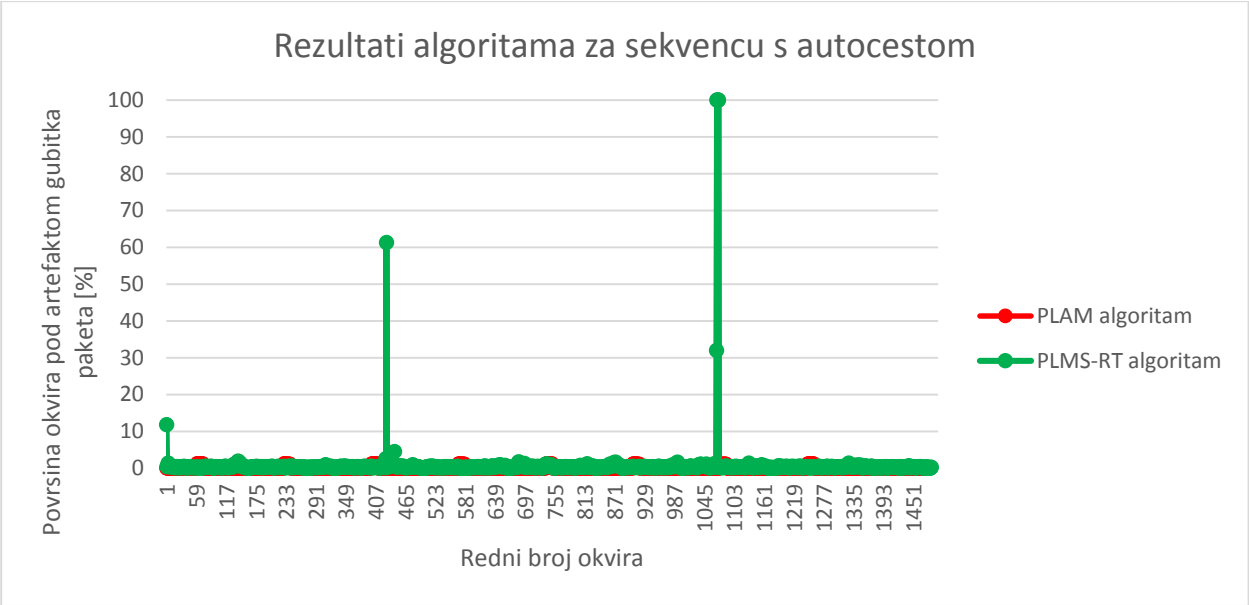
Sl. 5.6. *Odstupanje rezultata PLAM algoritma od stvarnih rezultata za slučajno odabrane okvire s malom količinom artefakata za sekvence iz PLGID baze*

Kako su artefakti često djelomično prikriveni te propagacijom njihovi oblici i karakteristike degradirani, točno određivanje površine vidljivih artefakata veoma je teško. Za okvire s malim brojem artefakta, u većini sekvenci algoritam prikazuje približnu površinu artefakata. Precijenjeni rezultati površine algoritma PLAM uzrokovani su detektiranjem izraženih rubova za makroblokove koji su u prethodnim okvirima imali artefakt gubitka, koji se nakon određenog broja okvira uklanjaju. Za okvire s većim brojem artefakta, algoritam također približno procjenjuje površinu. Međutim za veće količine artefakta, algoritam procjenjuje veću površinu od stvarne. Razlog tomu jest pojava neoštećenog reda makroblokova između dva reda makroblokova koji sadrže artefakte gubitka paketa. Neoštećeni makroblokovi u tom slučaju na gornjoj i donjoj granici makrobloka poprimaju izražene rubove te ukoliko se osim prvog zadovolji i jedan od preostalih uvjeta detekcije iz formule (4-23), nepravilno se detektira artefakt gubitka paketa na makrobloku.

Na slikama 5.7. i 5.8 prikazani su rezultati PLAM i PLMS-RT algoritama nad video sekvencama s umjetnim sadržajem i autocestom iz RT-RKD baze u kojima ne postoje artefakti gubitka paketa.



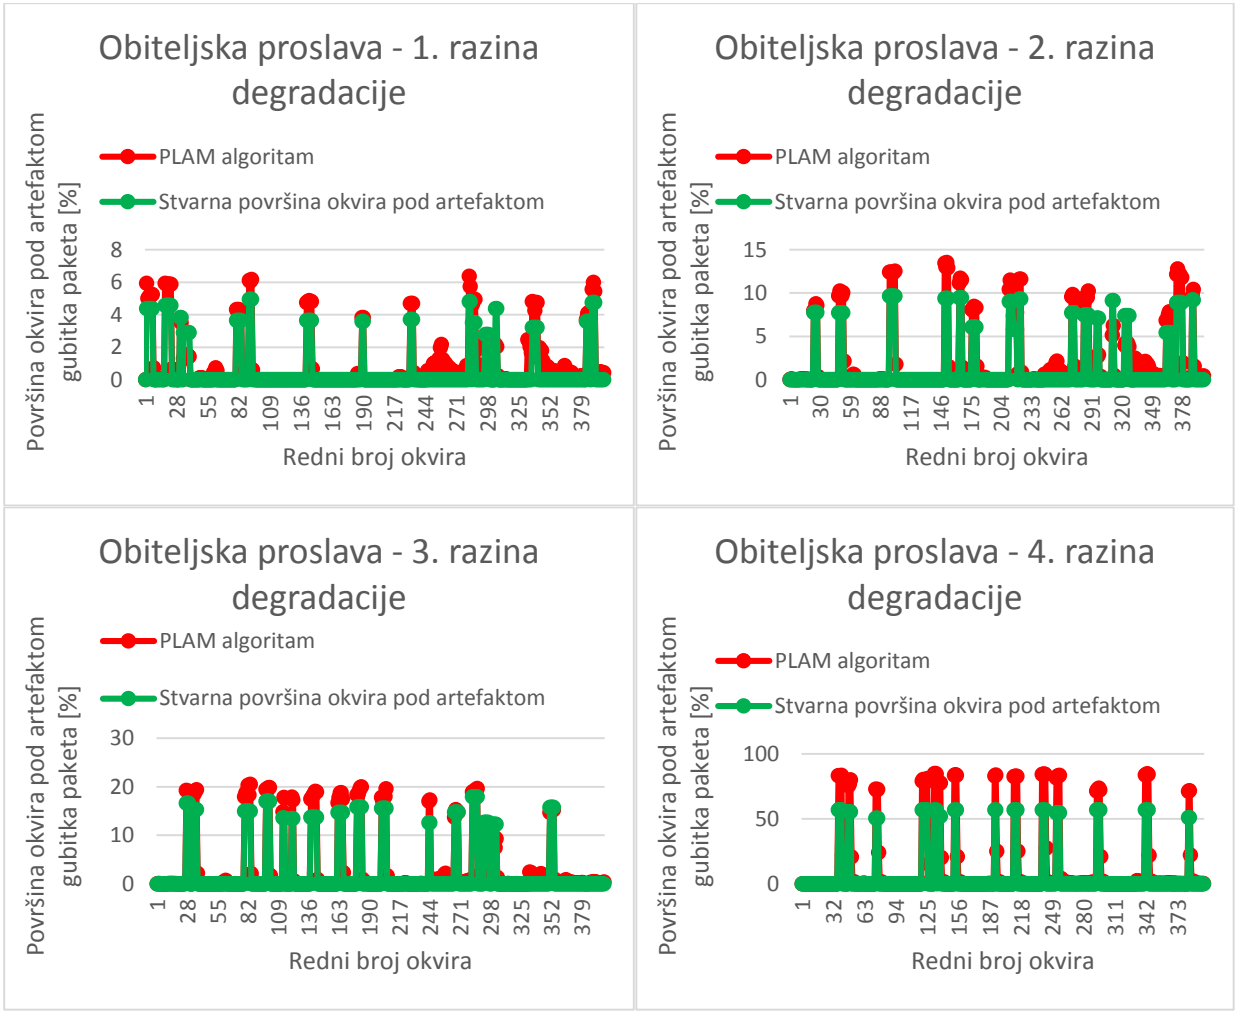
Sl. 5.7. *Rezultati PLAM i PLMS-RT algoritama za video sekvencu s umjetnim sadržajem iz RT-RKD baze*



Sl. 5.8. *Rezultati PLAM i PLMS-RT algoritama za video sekvence s autocestom iz RT-RKD baze*

Za video sekvencu s umjetnim sadržajem, algoritam PLMS-RT zbog velikog broja izraženih rubova ikona, okvira prozora i trake izbornika detektira veliki broj artefakta. Za razliku od toga, PLAM algoritam nije detektirao artefakte gubitka paketa na okvirima neoštećene video sekvence. Za video sekvencu s autocestom, oba algoritama detektiraju vrlo male vrijednosti artefakata na okvirima. No, PLMS-RT algoritam nepravilno detektira vrlo veliki broj artefakata na nekolicini neoštećenih okvira. Time se novi PLAM algoritam pokazao boljim od PLMS-RT algoritma.

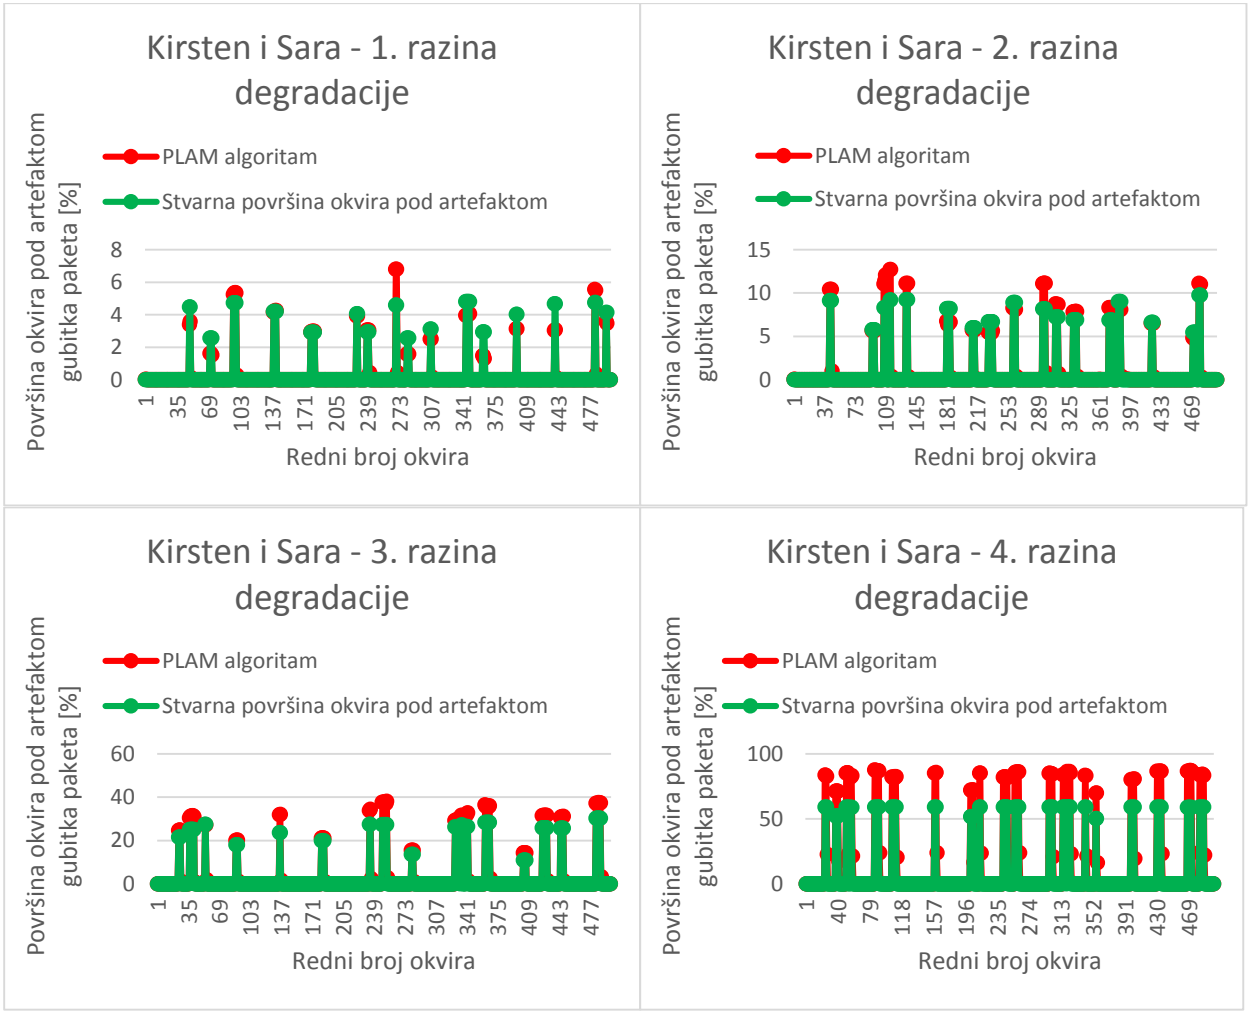
U nastavku, dani su rezultati PLAM i PLMS-RT algoritma za generirane video sekvence iz GRD baze s poznatom površinom okvira pod artefaktima gubitka paketa. Na slikama 5.9, 5.10, 5.11, 5.12 i 5.13. prikazani su grafovi s rezultatima algoritma PLAM za generirane video sekvence s 5 različitih sadržaja i 4 razine degradacije. Kao što se može uočiti na grafovima sa slika 5.3. i 5.4., rezultati PLMS-RT algoritma znatno su veći od rezultata PLAM algoritma, što je nepogodno za prikaz na istom grafu. Stoga su u tablicama 5.2, 5.3, 5.4, 5.5 i 5.6 uspoređeni rezultati PLAM i PLMS-RT algoritama. U tablicama su korištene dvije mjere: srednja vrijednost rezultata algoritma svih okvira video sekvence (MDV) i srednja vrijednost rezultata algoritma u okvirima gdje su umetnuti umjetno generirani artefakti gubitka paketa (MDF). Osim mjera PLAM i PLMS-RT algoritama, u tablicama se nalaze i referentne (stvarne) vrijednosti mjera MDV i MDF za video sekvence.



Sl. 5.9. *Rezultati PLAM algoritma za 4 razine degradacije video sekvence sadržaja "Obiteljske proslave" iz GRD baze*

Tab. 5.2. *Tablica usporedbe rezultata PLMS-RT i PLAM algoritama za 4 razine degradacije video sekvence sadržaja "Obiteljske proslave" iz GRD baze*

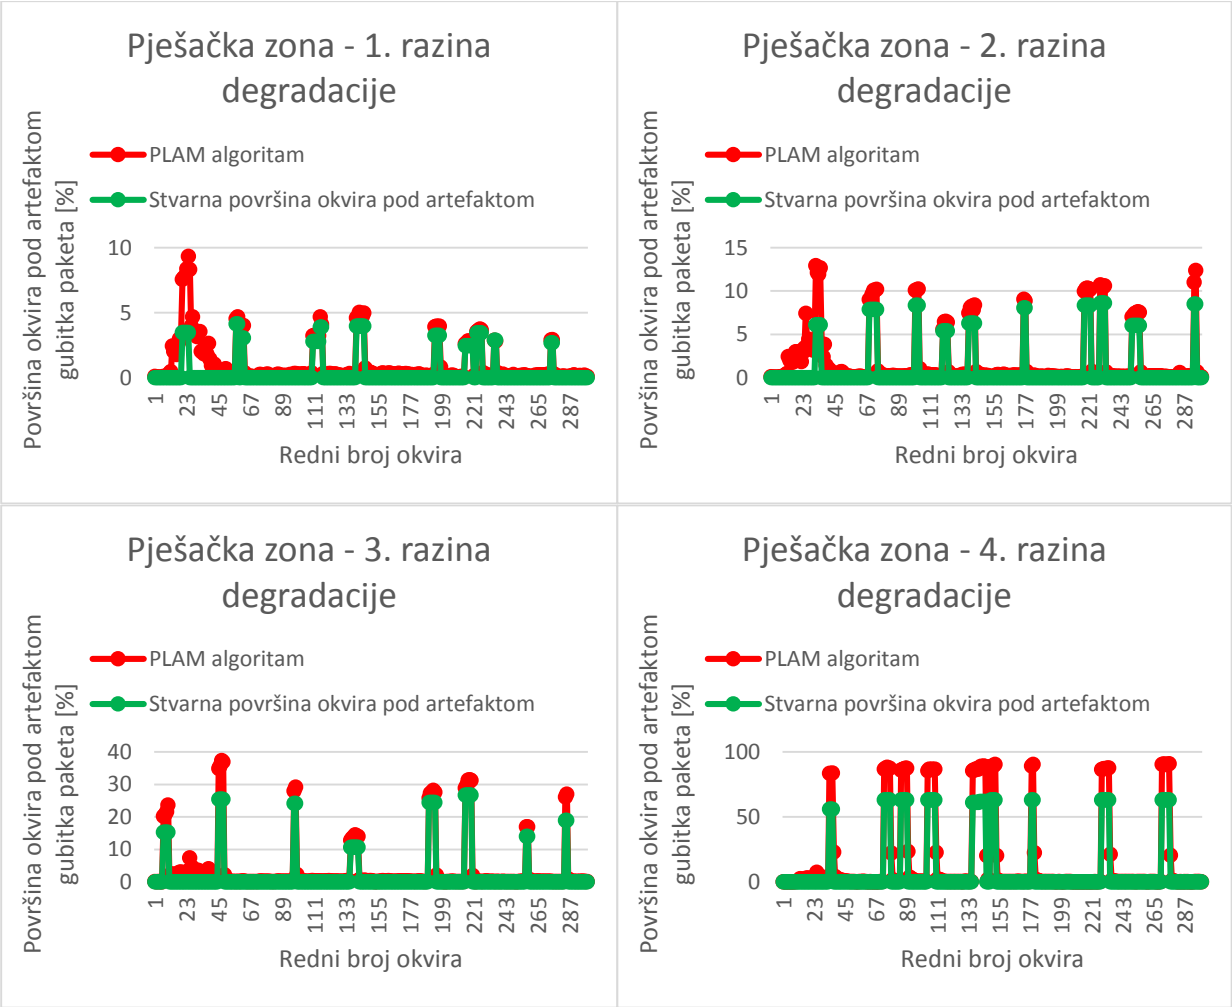
Razina degradacije	Referentni MDV [%]	Referentni MDF [%]	PLMS-RT MDV [%]	PLMS-RT MDF [%]	PLAM MDV [%]	PLAM MDF [%]
1	**0,57**	**3,82**	15,71	39,51	**0,84**	**4,33**
2	**1,35**	**7,9**	21,98	73,65	**1,80**	**9,267**
3	**2,50**	**14,91**	24,36	91,40	**2,99**	**16,72**
4	**6,86**	**55,83**	22,10	100,00	**10,92**	**80,31**



Sl. 5.10. *Rezultati PLAM algoritma za 4 razine degradacije video sekvence sadržaja "Kirsten i Sare" iz GRD baze*

Tab. 5.3. *Tablica usporedbe rezultata PLMS-RT i PLAM algoritama za 4 razine degradacije video sekvence sadržaja "Kirsten i Sare" iz GRD baze*

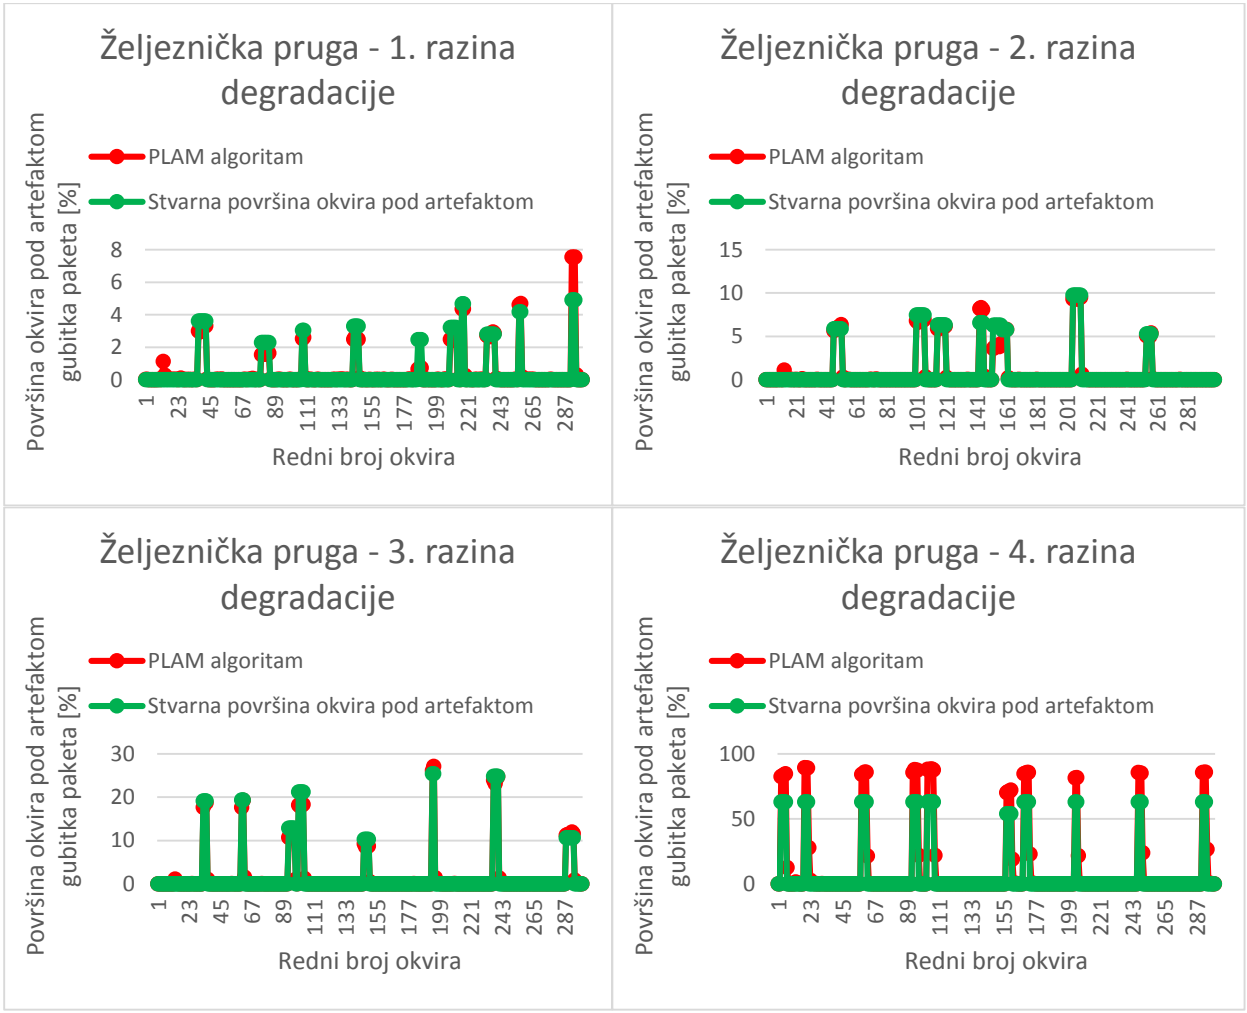
Razina degradacije	Referentni MDV [%]	Referentni MDF [%]	PLMS-RT MDV [%]	PLMS-RT MDF [%]	PLAM MDV [%]	PLAM MDF [%]
1	**0,35**	**3,80**	6,27	67,73	**0,32**	**3,47**
2	**1,01**	**7,54**	13,28	98,69	**1,09**	**8,03**
3	**3,32**	**24,37**	13,66	100,00	**4,10**	**29,61**
4	**10,15**	**58,24**	17,50	100,00	**15,38**	**83,00**



Sl. 5.11. *Rezultati PLAM algoritma za 4 razine degradacije video sekvence sadržaja "Pješačke zone" iz GRD baze*

Tab. 5.4. *Tablica usporedbe rezultata PLMS-RT i PLAM algoritama za 4 razine degradacije video sekvence sadržaja "Pješačke zone" iz GRD baze*

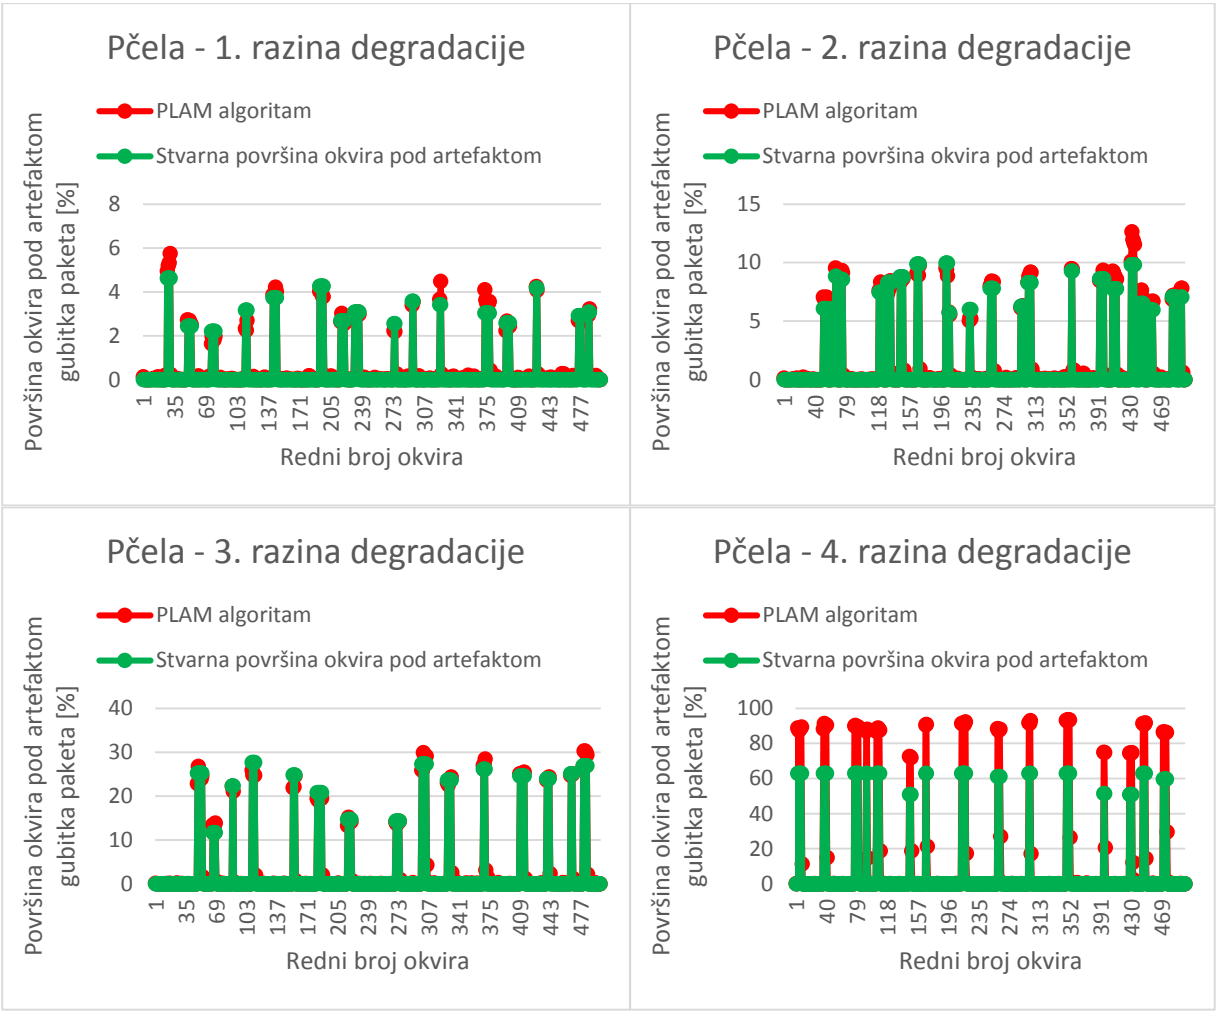
Razina degradacije	Referentni MDV [%]	Referentni MDF [%]	PLMS-RT MDV [%]	PLMS-RT MDF [%]	PLAM MDV [%]	PLAM MDF [%]
1	**0,43**	**3,25**	39,24	91,39	**0,96**	**4,25**
2	**0,99**	**7,20**	40,9	100,00	**1,70**	**9,32**
3	**1,99**	**19,87**	39,07	100,00	**2,98**	**24,89**
4	**9,78**	**62,24**	50,72	100,00	**14,96**	**87,66**



Sl. 5.12. *Rezultati PLAM algoritma za 4 razine degradacije video sekvence sadržaja "Željezničke pruge" iz GRD baze*

Tab. 5.5. *Tablica usporedbe rezultata PLMS-RT i PLAM algoritama za 4 razine degradacije video sekvence sadržaja "Željezničke pruge" iz GRD baze*

Razina degradacije	Referentni MDV [%]	Referentni MDF [%]	PLMS-RT MDV [%]	PLMS-RT MDF [%]	PLAM MDV [%]	PLAM MDF [%]
1	**0,43**	**3,26**	18,06	98,41	**0,40**	**2,95**
2	**0,93**	**6,78**	18,78	100,00	**0,89**	**6,37**
3	**1,67**	**16,68**	17,29	100,00	**1,63**	**15,78**
4	**7,47**	**62,00**	27,02	100,00	**10,94**	**84,28**



Sl. 5.13. *Rezultati PLAM algoritma za 4 razine degradacije video sekvence sadržaja "Pčele" iz GRD baze*

Tab. 5.6. *Tablica usporedbe rezultata PLMS-RT i PLAM algoritama za 4 razine degradacije video sekvence sadržaja "Pčele" iz GRD baze*

Razina degradacije	Referentni MDV [%]	Referentni MDF [%]	PLMS-RT MDV [%]	PLMS-RT MDF [%]	PLAM MDV [%]	PLAM MDF [%]
1	**0,40**	**3,17**	14,53	86,49	**0,43**	**3,19**
2	**1,35**	**7,75**	22,01	100,00	**1,46**	**8,10**
3	**3,03**	**22,55**	23,72	100,00	**3,11**	**22,51**
4	**7,56**	**60,89**	29,65	100,00	**11,46**	**87,38**

Na temelju dobivenih rezultata, može se zaključiti kako PLAM algoritam posjeduje veću točnost, preciznije rezultate i robusnost s obzirom na različite sadržaje video sekvenci u odnosu na algoritam PLMS-RT. Za video sekvence s prvom, drugom i trećom degradacijskom razinom

PLAM algoritam vrlo dobro aproksimira površinu okvira pod artefaktima gubitka paketa. Međutim na najvećoj razini degradacije video sekvenci algoritam precjenjuje površinu okvira pod artefaktima gubitka paketa.

Prema demonstriranim rezultatima, razvijeni PLAM algoritam posjeduje poboljšanu detekciju i mjeru u odnosu na uspoređeni komercijalni PLMS-RT algoritam. Algoritam se također pokazao robusnim s obzirom na sadržaj video sekvence. Nadalje, rezultati PLAM algoritma bolje aproksimiraju površinu artefakata za sekvence s manjom količinom artefakata, dok za sekvence s većom količinom artefakta algoritam precjenjuje površinu detektiranih artefakata. Kao što je prethodno rečeno, razlog tome jest povećani utjecaj oštećenih makroblokova na neoštećene makroblokove. Osim toga, PLAM algoritam ne detektira artefakte u video sekvencama koji ne sadrže artefakte gubitka paketa. Nadalje, zbog male računske složenosti, algoritam je pogodan za obradu u stvarnom vremenu za video sekvence visoke kvalitete (engl. *high-definition - HD*).

Skalirane video sekvence predstavljaju problem za detekciju u ovome algoritmu. Naime, zbog skaliranja, veličine makroblokova okvira se izmjenjuju, što onemogućava pravilnu detekciju. Osim promjene veličine makroblokova, rubovi artefakta na granicama makroblokova se interpoliraju, što uklanja stepeničastu diskontinuiranost te samim time i karakteristike artefakata gubitka paketa. Nadalje, u video sekvencama analiziranih proredom (engl. *interlaced video*) kod pokreta objekata nastaju artefakti analiziranog proreda koji predstavljaju izražene rubove koji su karakteristični za artefakte propagacije gubitka paketa. Osim toga, kako bi se detektirao artefakt propagacije, prethodno je potrebno uspješno detektirati pravokutni artefakt gubitka paketa. Ukoliko dekoder prikrije prvobitnu pogrešku, no propagacijom se pogreška proširi na niz okvira, PLAM algoritmom neće biti moguće detektirati spomenuti artefakt. To su neke od situacija u kojima još postoji mogućnost napretka rada PLAM algoritma.

6. ZAKLJUČAK

U radu predstavljen je razvijeni algoritam za detekciju artefakata nastalih gubitkom paketa pri prijenosu videa mrežom. Algoritam je niske računske složenosti, što ga čini pogodnim za obradu u stvarnom vremenu u sustavima ocjene kvalitete video signala. Prema dobivenim rezultatima, algoritam predstavlja poboljšanje u odnosu na uspoređeni komercijalni algoritam. Za razliku od ostalih algoritama, mjera predstavljenog algoritma objektivne je naravi. Nadalje, predstavljeni algoritam za detekciju artefakta pokazao je robusnost izvedbe nad različitim transportnim tokovima različitog formata i osjetljivost na različite vrste degradacije. Ograničenje predstavljenog algoritma leži u manjoj mogućnosti detekcije artefakata gubitka paketa u skaliranim video signalima i video signalima analiziranih s proredom. U tim slučajevima algoritam postiže nešto lošije performanse.

LITERATURA

[1] D. Shabtay, N. Raviv, Y. Moshe, „Video packet loss concealment detection based on image content“, 16th European Signal Processing Conference, str. 1-5, Švicarska, 2008.

[2] B. Juurlink, M. Alvarez-Mesa, C. C. Chi, A. Azevedo, C. Meenderinck, A. Ramirez, “ Scalable Parallel programming Applied to H.264/AVC Decoding“, Springer-Verlag, New York, 2012.

[3] V. Lo, A Beginners Guide for MPEG-2 Standard, (https://www.iem.thm.de/telekom-labor/zinke/mk/mpeg2beg/beginnzi.htm), pristup ostvaren 28.8.2016.

[4] G. J. Sullivan, J. R. Ohm, W.J. Han, T. Wiegand, „Overview of the High Effiency Video Coding (HEVC) Standard“, IEEE Transactions on Circuits and Systems for Video Technology, br. 12, sv. 22, str. 1649-1668, prosinac 2012.

[5] I. Glavota, M. Vranješ, M. Herceg, R. Grbić, „Pixel-based Statistical Analysis of Packet Loss Artifact Features“, Zinc Conference, str. 1-4, Srbija, 2016.

[6] M. Shahid, A. Rossholm, B. Lövström, H. J. Zepernick, „No-reference image and video quality assessment: a classification and review of recent approaches“, EURASIP Journal on Image and Video Processing, br. 1, sv. 2014., str. 1-32, kolovoz 2014.

[7] S. Kanumuri, P. C. Cosman, A. R. Reibman, V. A. Vaishampayan, „Modeling Packet-Loss Visibility in MPEG-2 Video“, IEEE Transactions on Multimedia, br. 2, sv. 8, str. 341-355, travanj 2006.

[8] H. Rui, C. Li, S. Qiu, „Evaluation of packet loss impairment on streaming video“, Journal of Zhejiang University Science A, br. 1, sv. 7, str. 131-136, siječanj 2006.

[9] N. Teslić, V. Zlokolica, V. Peković, T. Teckan, M. Temerinac, „Packet-Loss Error Detection system for DTV and set-top box functional testing“, IEEE Transactions on Consumer Electronics, br. 3, sv. 56, str. 1311-1319, kolovoz 2010.

[10] R. V. Babu, A. S. Bopardikar, A. Perkis, O. I. Hillestad, „No-reference metrics for video streaming applications“, 14th International Workshop on Packet Video, SAD, prosinac 2004.

[11] E. P. Ong et al., „Video quality monitoring of streamed videos“, IEEE International Conference on Acoustics, Speech and Signal Processing, str. 1153-1156, Republika Kina, travanj 2009.

[12] T. Yamada, Y.Miyamoto, M. Serizawa, „No-reference video quality estimation based on error-concealment effectiveness“, IEEE Packet Video, str. 288-293, Švicarska, studeni 2007.

[13] RTRK, (http://bbt.rt-rk.com/), pristup ostvaren 28.8.2016.

[14] Baza video signala, (https://media.xiph.org/video/derf/), pristup ostvaren 28.8.2016.

SAŽETAK

U ovome radu opisane su najzastupljenije norme korištene za kompresiju video signala. Opisana je klasifikacija objektivnih metoda ocjene kvalitete video signala. Prikazana je manifestacija artefakata gubitka paketa nastalih pri prijenosu videa mrežom. Dan je pregled postojećih algoritama za detekciju artefakata nastalih zbog gubitka paketa u mreži. Predstavljen je vlastiti algoritam za detekciju artefakata nastalih zbog gubitka paketa pri prijenosu videa mrežom temeljen na pristupu bez izvorne reference. Rezultati dobiveni razvijenim algoritmom uspoređeni su s postojećim algoritmima za detekciju artefakata gubitka. Novi algoritam postiže znatno bolje rezultate od nekih komercijalnih algoritama za širok skup testiranih video signala.

Ključne riječi:
Kompresija videa, objektivne metode, artefakt gubitka paketa, pristup bez referentnog signala, algoritam za detekciju artefakata, PLAM

DETECTION OF PACKET LOSS FOR NETWORK TRANSMITTED VIDEO

ABSTRACT

This paper describes the most common standards used in video compression. The paper describes the classification of objective methods used in video quality assessment. Manifestation of packet loss artifacts is presented. An overview of existing algorithms for the detection of artifacts caused by packet loss is shown. In this paper, a novel algorithm for packet loss artifacts detectection is proposed. Results obtained from the proposed algorithm are compared to these of existing algorithms for packet loss artifacts detection. The new algorithm achieves significantly better results than some commercial algorithms for a broad set of test video signals.

Keywords:
Video compression, objective methods, packet loss artifacts, no-reference, detection algorithm, PLAM

ŽIVOTOPIS

Ivan Glavota rođen je 23.4.1993. godine u Aubervilliersu u Francuskoj. 2014. godine završava sveučilišni preddiplomski studij računarstva na Elektrotehničkom fakultetu u Osijeku. Student je 2. godine sveučilišnog diplomskog studija računarstva (s odličnim prosjekom na diplomskom studiju). 1.10.2015. postaje stipendist i praktikant Instituta RT-RK Osijek. Poznaje sljedeće programske jezike i formalizme: C++, C#, Java, Python, Ruby, JavaScript, HTML, CSS, SQL i PHP. Poznaje izvrsno engleski jezik te pasivno govori, priča i piše francuski jezik.