VREDNOVANJE RJEŠENJA ZA DETEKCIJU ARTEFAKTA SMRZAVANJA SLIKE NA NOVOSTVORENOJ BAZI VIDEO SIGNALA

Vrtar, Ela

Master's thesis / Diplomski rad

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:200:026180

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2025-03-24**

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

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

Sveučilišni studij

VREDNOVANJE RJEŠENJA ZA DETEKCIJU ARTEFAKATA SMRZAVANJA SLIKE NA NOVOSTVORENOJ BAZI VIDEO SIGNALA

Diplomski rad

Ela Vrtar

Osijek, 2022.

SADRŽAJ

1. UVOD 1

2. ARTEFAKT SMRZAVANJA SLIKE U VIDEO SIGNALU 3

2.1. Gubitak paketa 3

2.1.1. Smrzavanje okvira 3

2.2. Metoda ocjene kvalitete videosignala 4

2.2.1. Subjektivne metode za ocjenu kvalitete videosignala 4

2.2.2. Objektivne metode za ocjenu kvalitete videosignala 5

2.3. Postojeći algoritmi za detektiranje artefakata smrzavanja slike u video sekvencama 7

2.3.1. HBFDA algoritam 7

2.3.2. RTFDA algoritam 9

2.4. Opis dostupnih baza video sekvenci s prisutnim artefaktom smrzavanja slike 9

2.4.1. LIVE Mobile baza podataka 10

2.4.2. VQEG HD baza podataka 12

2.4.3. FERIT – RTRK UHD VFD baza podataka 13

3. KREIRANA BAZA VIDEO SEKVENCI S PRISUTNIM ARTEFAKTOM SMRZAVANJA 15

3.1. Opis video sekvenci SMVS FullHD baze 16

3.2. SI-TI karakteristike video sekvenci SMVS FullHD baze 20

3.3. Generiranje artefakta smrzavanja 23

3.4. Potvrda artefakta smrzavanja 23

4. EVALUACIJA I VERIFIKACIJA DOSTUPNIH ALGORITAMA ZA DETEKCIJU ARTEFAKATA SMRZAVANJA NA NOVOSTVORENOJ BAZI PODATAKA 26

4.1. Rezultati algoritama nad SMVS FullHD bazi podataka 27

5. ZAKLJUČAK 33

LITERATURA 34

SAŽETAK 35

ABSTRACT 36

ŽIVOTOPIS 37

1. UVOD

Razvoj telekomunikacijskih tehnologija omogućio je prijenos video sekvenci putem Interneta što je postalo sastavnim dijelom života ljudi. Video sekvence postaju neizbježan dio komunikacije, prodaje, marketinga, zabave te su ključan alat u procesu obuke i učenja. Takav brz porast multimedijskih usluga i njihove korisničke potražnje, gdje se milijuni ili čak milijarde video sekvenci generiraju, prenose i dijele Internetom, zahtjeva rigorozno i interaktivno praćenje kvalitete ponuđenog sadržaja. Zadatak isporuke sadržaja često može biti izazovan jer se video sekvence obično prenose kroz okruženja sklona pogreškama što može dovesti do određenih degradacija dok krajnji korisnici žele maksimalno iskoristiti mogućnosti svojih uređaja kako bi uživali u visokokvalitetnom sadržaju.

Pogreške u video sekvencama mogu biti posljedica pogreške u implementaciji kodera ili dekodera, snimanju, kompresije, kodiranja, prijenosa, reprodukcije, dekodiranja i prikazivanja videozapisa koje imaju izravan utjecaj na njegovu vizualnu kvalitetu. Te se pogreške mogu klasificirati u hardverske, softverske i pogreške prijenosa. Pogreške u prijenosu kao što su gubitak paketa i podataka mogu se dogoditi zbog greške uzrokovane prijenosom signala komunikacijskim kanalom.

Sustav za digitalni video prijenos video signala obično uključuje koder, kanal za prijenos i dekoder na strani prijema. Sva tri dijela prijenosnog sustava mogu uzrokovati različite vrste oštećenja ili degradacije u kvaliteti video sekvenci. Prijenosni kanal ima ograničenu širinu prijenosnog pojasa, stoga je video signale potrebni prikladno obraditi (npr. komprimirati) kako bi bili prikladniji za prijenos, pohranu i prikazivanje. Kompresija se koristi kako bi se smanjila količina podataka potrebna da se video sadržaj prenese ili pohrani. Međutim, takvom obradom dolazi do degradacije vizualne kvalitete video sekvence. Kao posljedica toga, krajnji korisnik može vidjeti značajno izmijenjenu video sekvencu u usporedbi s onom izvornom. Nakon kompresije video sekvenca se prenosi prijenosnim kanalom do svog odredišta. Prijenosni kanali mogu uzrokovati pogreške prilikom prijema signala što može unijeti smetnje kao što su kašnjenje i gubitak paketa. Nakon prolaska kroz medij ili kanal, odaslani video sadržaj stiže na svoje odredište koje se naziva prijemnik koji obavlja rekonstrukciju odaslane video sekvence.

Kako bi se mogla ocijeniti kvaliteta video signala u nekoj prijenosnoj mreži, potrebno je specijaliziranim algoritmom detektirati artefakte koji se mogu pojaviti. Postoje prijenosni sustavi kod kojih nije poznata izvorna video sekvenca te tada govorimo o prijenosnim sustavima bez reference. Kod takvih sustava detekcija artefakata vrši se „na slijepo“, tj. algoritmi moraju biti

dizajnirani i implementirani da artefakt slike prepoznaju bez usporedbe s izvornim video sadržajem. Smrzavanje okvira često je uočen artefakt koji je posljedica gubitka i kašnjenja paketa. Kada dođe do gubitka paketa, neki okviri se gube, a kako bi se izbjegao prekid u prikazu, posljednji uspješno preneseni okvir se ponavlja određeno vrijeme dok novi okvir nije dostupan. Identifikacija smrznutih okvira vrlo je važan zadatak u tehnikama procjene kvalitete videa. Postojeći objavljeni algoritmi za detekciju artefakta smrzavanja su dizajnirani, implementirani i precizno optimizirani koristeći sadržaje iz do sada objavljenih baza video sekvenci. Zadatak ovog rada je istražiti postoje li video sekvence za koje algoritmi za detekciju artefakata smrzavanja ne daju dobre rezultate i ukoliko postoje, usmjeriti izradu nove baze video sekvenci tako da generirani video signali smisleno dopunjuju postojeće baze.

Drugo poglavlje donosi teorijsku pozadinu uzroka i posljedica pojave smrzavanja video sekvenci te opisuje način rada postojećih algoritama za detekciju smrzavanja slike u video signalu. Također, sadrži detaljnu analizu postojećih baza video sekvenci s prisutnim artefaktom smrzavanja slike koje su korištene prilikom testiranja u spomenutim algoritmima. Nadalje, u trećem poglavlju detaljno je opisana novostvorena baza i način generiranja smrzavanja. U četvrtom poglavlju ispitana je točnost rezultata implementacije algoritama nad postojećim bazama te uspješnost detekcije artefakta smrzavanja nad novostvorenom bazom podataka.

2. ARTEFAKT SMRZAVANJA SLIKE U VIDEO SIGNALU

Kvaliteta video sekvenci (engl. *Video quality*) je mjera percipirane degradacije video sekvence koji prolazi kroz kanal, a njena procjena na temelju određenih pretpostavki naziva se procjena kvalitete videa (engl. *Video quality assessment*) [1]. Prijenosi kanali nisu savršeni te unose artefakte u video sekvence koje se njima prenose. Razvoj algoritama koji detektiraju moguće artefakte predstavlja prvi korak prema unaprjeđenju kvalitete prijenosnog sustava.

2.1. Gubitak paketa

Prijenos video sekvenci putem prijenosnog kanala odvija se u obliku paketa. Izvorna video sekvenca dijeli se na manje dijelove, pakete, koji omogućuju lakše upravljanje i prijenos. Ti paketi sadrže manju količinu podataka kako bi se osigurao brži prijenos. Zbog grešaka u mreži neki od tih paketa se ne prenesu uspješno. Kao rezultat toga dolazi do gubitka paketa (engl. *packet loss*). Uzrok gubitka paketa može biti pogrešna konfiguracija hardvera, ograničena širina pojasa i neusklađenost dupleksera [1]. Gubitak paketa ključan je čimbenik koji određuje kvalitetu multimedijskih aplikacija osjetljivih na kašnjenje kao što su audio/video konferencije i internetska telefonija [2]. Različite vrste paketa s različitim udaljenostima i frekvencijama gubitaka mogu dovesti do različite kvalitete video sekvenci.

2.1.1. Smrzavanje okvira

Kada dođe do gubitka paketa, neki okviri se gube, a kako bi se izbjegao prekid u prikazu, posljednji uspješno preneseni okvir se ponavlja određeno vrijeme dok novi okvir nije dostupan. Ovisno o dopuštenom vremenu kašnjenja, postoje dvije vrste artefakata smrzavanja okvira. Tip smrzavanja određuje cijeli prijenosni sustav, ovisno o tome da li je sustav s retransmisijom ili ne. Ukoliko se radi o sustavu s retransmisijom, prijemnik šalje informaciju odašiljaču da okvir nije uspješno primljen te odašiljač vrši ponovno slanje tog okvira. Ukoliko nema retransmisije, odašiljač šalje jedan okvir za drugim.

U aplikacijama koje ne toleriraju kašnjenje (kao što su videokonferencije ili prijenos uživo), svaki okvir koji nije u potpunosti primljen do roka za prikaz smatra se izgubljenim, a prijemnik odabire određenu metodu prikrivanja pogreške. Uobičajena i popularna metoda prikrivanja pogrešaka je korištenje prethodnog okvira koji je ispravno primljen. Ukoliko se koristi predikcijsko kodiranje, sljedeći okvir će sadržavati pogrešku prilikom dekodiranja. Kako bi se izbjegao takav problem širenja pogreške, svi sljedeći okviri nakon izgubljenog okvira također se zamjenjuju istim, zadnjim ispravno primljenim okvirom. To se odvija sve dok se ne primi sljedeći ispravno preneseni okvir.

Reprodukcija će se nastaviti od sljedećeg ispravno prenesenog okvira, odnosno svi okviri koji su poslani a nisu primljeni neće biti prikazani. U ovom slučaju, slika se smrzava i preskače se određeni dio videozapisa. Drugi naziv za ovaj artefakt je ispuštanje okvira ili „smrzavanje s preskakanjem“, a do njega dolazi zbog gubitka paketa.

U aplikacijama koje dopuštaju fleksibilniju odgodu, kao što je streaming unaprijed kodiranog videa, kada okvir ne stigne nakon roka za prikaz, prijemnik kontinuirano prikazuje prethodni okvir, sve dok ne stigne stvarni novi okvir. Ukoliko se radi o sustavu s retransmisijom, moguće je od pošiljatelja zatražiti ponovno slanje te je na taj način omogućena reprodukcija okvira koji u referentnom sadržaju slijedi nakon posljednjeg ispravno prenesenog okvira tj. nakon okvira koji se ponavljao tijekom intervala smrzavanja. Takvo smrzavanje naziva se još i „smrzavanje bez preskakanja“ ili zaustavljanje okvira. Do smrzavanja okvira dolazi zbog kašnjenja paketa. Oba se artefakta manifestiraju kao vremenski trzaji na primljenoj video sekvenci [2].

2.2. Metoda ocjene kvalitete videosignala

Ispušteni ili ponovljeni okviri imaju negativan utjecaj na kvalitetu iskustva (engl. *Quality of experience* – QoE) korisnika. Otkrivanje ispuštenih okvira važno je kako bi se pratila kvaliteta prijenosnog sustava, a također i kako bi se ispunili zahtjevi ugovora o razini usluge (engl. *Service - level agreement* – SLA) [3]. Metode ocjene kvalitete videosignala mogu se podijeliti na subjektivne i objektivne metode.

2.2.1. Subjektivne metode za ocjenu kvalitete videosignala

Subjektivna metoda predstavlja najtočniju metodu za dobivanje ocjene kvalitete. U takvom eksperimentu sudjeluje nekoliko „subjekata“ (obično 15-30) od kojih se traži da pregledaju niz video isječaka i ocjene njihovu kvalitetu [4]. Prosječna ocjena svih gledatelja za određenu video sekvencu poznata je kao srednja ocjena mišljenja (engl. *Mean Opinion Score* – MOS). Rezultat takvog postupka daje najtočniju i najprecizniju ocjenu kvalitete video sekvenci. Budući da svaki pojedinac ima različite interese i očekivanja od video sekvence, subjektivnost i varijabilnost ocjena gledatelja ne može se u potpunosti eliminirati. Ti negativni čimbenici pokušavaju se minimizirati primjenom preciznih uputa, obukom i ispitivanjem u kontroliranom okruženju. Glavni nedostatak subjektivne metode je zahtjev za velikim brojem gledatelja, što ograničava količinu video sekvenci koji se mogu ocijeniti u razumnom vremenu. Ipak, subjektivni eksperimenti ostaju mjerilo za bilo koju objektivnu metodu ocjene kvalitete videosignala.

2.2.2. Objektivne metode za ocjenu kvalitete videosignala

Objektivno mjerenje kvalitete temelji se na dizajniranju matematičkog modela koji uključuje parametre koji utječu na kvalitetu video sekvenci. Vrijednosti kvalitete video sekvenci dobivene subjektivnim testiranjem uspoređuju se s vrijednostima dobivenim objektivnim testiranjem kako bi se saznala pouzdanost metrike. Postoje mnoge metode objektivnog mjerenja kvalitete, a razlikuju se po dostupnosti referentne video sekvence u predviđanju kvalitete. Tri su kategorije na koje se dijele objektivne metode za ocjenu kvalitete [2]:

- Metrike koje zahtijevaju sve informacije o referentnoj video sekvenci (engl. *Full-reference*, **FR**)
- Metrike koje ne zahtijevaju nikakve informacija o referentnoj video sekvenci (engl. *No-reference*, **NR**)
- Metrike koje zahtijevaju djelomične informacije o referentnoj video sekvenci (engl. *Reduced- reference*, **RR**)

FR metrikom uspoređuje se okvir po okvir referentne i izobličene video sekvence. Ova metrika zahtijeva da cijela referentna video sekvenca bude dostupna, da je u nekomprimiranom obliku te da ne sadrži pogreške. Nadalje, FR metrika općenito nameće precizno prostorno i vremensko poravnanje dvije video sekvence, tako da se svaki element slike u svakom okviru može upariti sa svojim ekvivalentom u drugom isječku. Ova metrika obično ne reagira dobro na promjene svjetline, kontrasta ili boje i zahtjeva odgovarajuću kalibraciju video sekvenci. Najveći problem predstavlja ograničenost njene primjene. Naime, ograničena je samo na izvan mrežno mjerenje kvalitete video sekvenci jer u aplikacijama u stvarnom vremenu u slučaju emitiranja uživo, dostupnost izvorne video sekvence nije moguća. Za testiranje video prijenosa uživo potrebne su metode koje su vrlo brze jer se kod takvih prijenosa ne može dopuštati kašnjenje. Slikom 2.1. prikazan je dijagram koji objašnjava kako funkcionira FR metrika, iako u komunikaciji u stvarnom vremenu nije moguće imati originalnu video sekvencu na prijemnoj strani, ali u laboratorijskim slučajevima to je moguće.

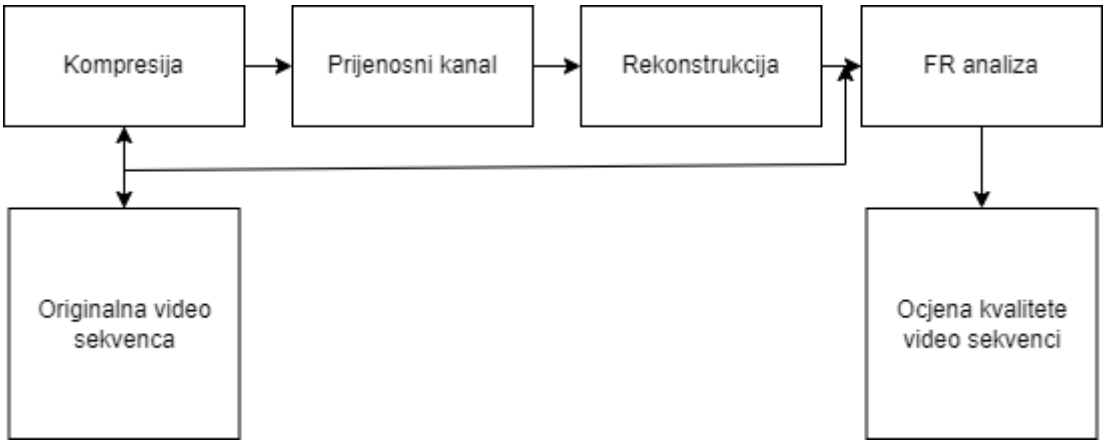

Slika 2.1. Dijagram sustava za prijenos digitalne video sekvence s ocjenom kvalitete videa FR metrikom [2]

S druge strane, NR metrika analizira samo reproduciranu video sekvencu, bez potrebe za poznavanjem referentne video sekvence. To ju čini fleksibilnijom od FR metrike jer u nekim slučajevima može biti teško ili nemoguće dobiti pristup referentnoj sekvenci. Glavni izazov NR metrike leži u razlikovanju izobličenja od sadržaja, što je razlika koju ljudi obično mogu napraviti iz iskustva. U aplikacijama u stvarnom vremenu informacije o vrsti izobličenja nisu dostupne, stoga je ova metrika najpogodnija za procjenu kvalitete prilikom emitiranja uživo. Metrika dizajnirana na takav način može, ali i ne mora imati pretpostavke temeljena na vrsti izobličenja. No, tijekom evaluacija, za obuku su potrebni neki primjeri sa sličnim izobličenjem. Slikom 2.2 prikazan je dijagram koji objašnjava kako funkcionira NR metrika.

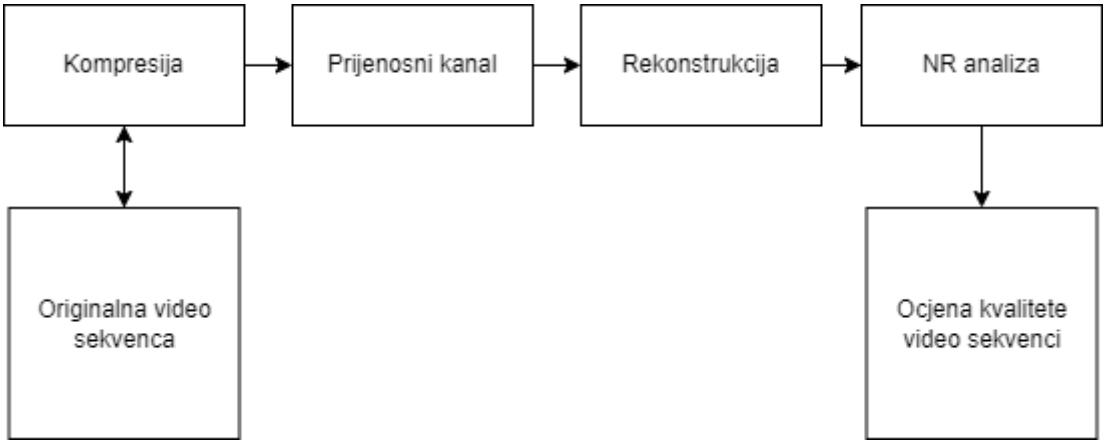

Slika 2.2. Dijagram sustava za prijenos digitalne video sekvence s ocjenom kvalitete videa NR metrikom [2]

RR metrika predstavlja kompromis između FR i NR metrike. Ova metrika izdvaja samo neke parametre iz referentne i reproducirane sekvence, tj. za analizu je potrebno samo djelomično poznavanje informacija o referentnoj video sekvenci. Primjeri značajki su količina paketa ili prostornih detalja.

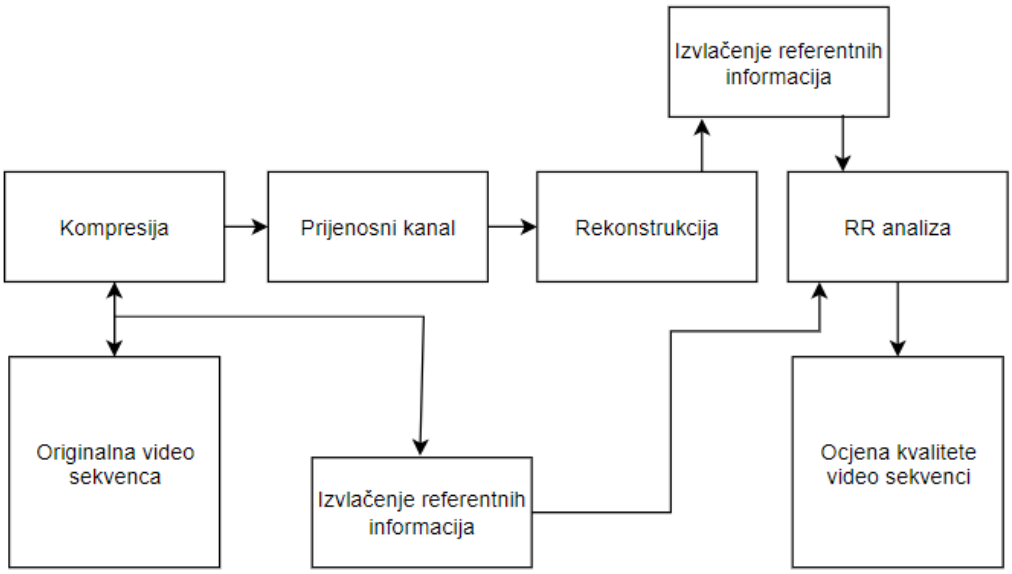

Slika 2.3. Dijagram sustava za prijenos digitalne video sekvence s ocjenom kvalitete videa RR metrikom [2]

2.3. Postojeći algoritmi za detektiranje artefakata smrzavanja slike u video sekvencama

Kako bi pravovremeno detektirao artefakt smrzavanja, kreirani su algoritmi za njihovu detekciju. Ključan je razvoj brzih (zbog zahtjeva rada u stvarnom vremenu) i robusnih mjera za procjenu količine promjene sadržaja između dvije slike. Algoritmi moraju prepoznati vrlo male promjene sadržaja, a u isto vrijeme moraju biti otporni na šum i male promjene svjetline. U ovom radu proučena su dva algoritma koja ne zahtijevaju nikakve informacije o referentnoj video sekvenci, NR algoritmi, HBFDA (engl. *Histogram-Based Freezing artifacts Detection Algorithm*) [5] algoritam i RTFDA (engl. *Real-Time no-reference Freezing Detection Algorithm*) [6] algoritam, dok je detaljan opis njihova rada dan u potpoglavljima koja slijede.

2.3.1. HBFDA algoritam

Algoritam predložen u [4] naziva se HBFDA. Rad algoritma može se podijeliti na dva dijela. Prvi dio odnosi se na izračun prostorne aktivnosti između dva uzastopna okvira na temelju histograma

svake regije, dok se drugi dio odnosi na procjenu smrzavanja na temelju izračunate vremenske aktivnosti kretanja, odnosno donošenju odluke da li je prisutno smrzavanje ili ne.

Za postizanje boljih performansi u stvarnom vremenu i brzine obrade, multimedijski alati i aplikacije za izračun aktivnosti pokreta koriste samo luminantnu komponentu (Y) ulazne YUV video sekvence [4]. Iz svakog se okvira izdvaja vrijednost luminantne komponente te se pohranjuje u matricu koja se koristi u daljnjoj obradi. Kako bi se smanjio učinak šuma prilikom otkrivanja artefakata smrzavanja u analiziranoj video sekvenci, video okvir se filtrira Gaussovim filtrom. Zatim se računa apsolutna razlika između izvorne i filtrirane matrice te se ta razlika dijeli na regije istih veličina, što rezultira različitim ukupnim brojem regija za različite rezolucije. Za svaku regiju računa se histogram iz vrijednosti svjetline elemenata slike, a korelacija histograma trenutne i prethodne matrice uspoređuje se Hi- kvadrat testom. Dobivena vrijednost korelacije za svaku regiju predstavlja konačnu procjenu aktivnosti kretanja u pojedinoj regiji, koja će se dalje koristiti za odlučivanje je li se artefakt smrzavanja pojavio ili ne.

Za svaki okvir algoritam pronalazi omjer između broja nestatičkih regija i ukupnog broja regija. Statičke regije mogu se definirati kao područje koje ima procjenu aktivnosti kretanja toliko nisku da postoji gotovo apsolutna sigurnost da su ista područja uzastopnih okvira ista. Prag koji se koristi za određivanje može li se regija deklarirati kao statička ili ne unaprijed je definiran. Omjer se množi s fiksnim pragom aktivnosti te ta vrijednost predstavlja promjenjiv prag iteracije. Zatim se dobivene vrijednosti sortiraju uzlaznim redoslijedom (od najmanje aktivne regije do najaktivnije regije).

Prije nego što se može donijeti konačan zaključak o otkrivenom smrzavanju okvira, dva se uzastopna okvira moraju usporediti kako bi se provjerila njihova sličnost. Ako su dva okvira dovoljno slična i trenutni je okvir prvi u nizu potencijalno smrznutih okvira, prethodni okvir postaje posljednji okvir bez artefakta smrzavanja. Nadalje, histogrami trenutnog okvira kopiraju se u histograme prvog okvira u seriji da bi se kasnije usporedili s histogramima sljedećih okvira. Brojač uzastopnih okvira u intervalu smrzavanja povećava se za 1. Ako je vrijednost brojača jednaka ili veća od zadane vrijednosti, donosi se zaključak da je u video sekvenci došlo do smrzavanja jednog njenog dijela.

Poneke video sekvence mogu sadržavati vrlo malo kretanja, odnosno gotovo da nema aktivnosti kretanja između uzastopnih okvira. U tom slučaju potrebno je provjeriti stvarno smrzavanje okvira. Ukoliko je detektirano stvarno smrzavanje okvira, postoji brojač koji osigurava da detekcija prekida smrzavanja od jednog okvira ne prekine detekciju ukoliko se poslije tog okvira smrzavanje

nastavlja. U protivnom bi automatski došlo do prekida u detekciji. Ako je detektirano više od jednog okvira kod kojih je detektirana neka aktivnost, detekcija prestaje.

2.3.2. RTFDA algoritam

U radu [5], opisan je način rada RTFDA algoritma. Za potrebe detekcije smrzavanja, dovoljno je analizirati samo luminantnu komponentu ulazne YUV video sekvence. Rad RTFDA algoritma temelji se na usporedbi trenutnog okvira kojeg je moguće označiti s F_i i okvira F_{i-b}, gdje parametar *b* definira minimalno trajanje događaja smrzavanje koje bi algoritam mogao detektirati, a parametar *i* definira broj trenutnog okvira . Za video sekvencu brzine izmjene okvira od 25 okvira u sekundi preporučena vrijednost parametra *b* je 5, što znači da događaj smrzavanja mora trajati najmanje 6 okvira kako bi ga algoritam detektirao. Vrijednost parametra *b* može se prilagoditi različitim video sekvencama s različitim brzinama izmjene okvira, kao i različitim zahtjevima korisnika. Općenito, za RTFDA, predložena vrijednost parametra *b* se može dobiti kao brzina kadrova video sekvence (izražena u broju okvira u sekundi) podijeljena s 5.

Da bi se učinkovito procijenilo jesu li okviri jednaki ili ne, potrebno je eliminirati utjecaj superponiranog šuma te zatim usporediti strukturu okvira sa strukturom prethodnog okvira. Za razliku od prethodno opisanog algoritma [5] koji koristi Gaussov filtar, ovaj algoritam koristi filtar pomične srednje vrijednosti (engl. *Moving average filter*), veličine *D*x*D*, gdje *D* predstavlja korak pomaka. Kada se takav filtar primjeni na okvir F_i, poduzorkovani okvir *Si* dobiva se s visinom jednakom *H*/*D* i širinom jednakom *W*/*D* (*H* predstavlja visinu okvira, dok *W* predstavlja širinu okvira).

Usporedba trenutnog okvira F_i i okvira F_{i-b} izvodi se usporedbom dobivenih poduzorkovanih okvira S_i i S_{i-b}. Okviri F_i i F_{i-b} smatraju se jednakima ako je vrijednost broja elemenata njihove razlike ispod određenog, unaprijed definiranog praga.

2.4. Opis dostupnih baza video sekvenci s prisutnim artefaktom smrzavanja slike

Kako bi se ispitala uspješnost detekcije artefakta smrzavanja slike, potrebno je ispitivanje provesti na nekoliko različitih baza podataka. Svaka baza je jedinstvena te se razlikuje po sadržaju, trajanju, rezoluciji sekvenci i različitom tipu izobličenja. Od svih javno dostupnih baza izabrane su tri baze korištene pri testiranju HBFDA i RTFDA algoritma: LIVE Mobile, VQEG HD i FERIT-RTRK UHD VFD baza podataka. U narednim dijelovima teksta detaljno je opisan sadržaj svake baze kao i tipovi artefakta, razina i tip šuma te karakteristike pojedinačnih sekvenci.

2.4.1. LIVE Mobile baza podataka

„LIVE *Public - Domain Subjective Mobile Video Quality Database*“ (dalje u tekstu LIVE Mobile baza) sastoji se od 200 degradiranih video sekvenci kreiranih iz 10 RAW HD referentnih video sekvenci [7]–[9]. Sve izvorne video sekvence od kojih se baza sastoji su u HD rezoluciji (720p), trajanja 15 sekundi i brzine izmjene okvira 30 okvira u sekundi. Svaka referentna video sekvenca bila je podvrgnuta nizu izobličenja uključujući: kompresiju, gubitak paketa bežičnog kanala, smrzavanje okvira, prilagodba brzine i vremenska dinamika. Za testiranje algoritama [5] i [6] odabrano je, iz većeg skupa, 10 video sekvenci različitog sadržaja u kojima je prisutan artefakt smrzavanja okvira.

Dvije vrste modela smrzavanja okvira korištene su za stvaranje degradiranih videozapisa:

- Smrzavanje okvira za isporuku pohranjene video sekvence
- Smrzavanje okvira za isporuku video sekvence uživo.

U slučaju pohranjenih video sekvenci, smrzavanje okvira ne rezultira gubitkom video segmenta, dok s druge strane, smrzavanje okvira u isporuci uživo rezultira gubitkom video segmenata, odnosno nedostatkom vremenskog kontinuiteta. Od svake referentne video sekvence napravljene su po 4 degradirane, odnosno video sekvence istog sadržaja, no s prisutnim artefaktom smrzavanja različitog trajanja. Video sekvence su kodirane pomoću H.264 kodera.

U svakoj video sekvenci prisutno je nekoliko intervala smrzavanja, a duljine trajanja intervala su sljedeće:

- 1 sekunda (video sekvenca s 8 intervala smrzavanja)
- 2 sekunde (video sekvenca s 4 intervala smrzavanja)
- 4 sekunde (video sekvenca s 2 intervala smrzavanja)

Duljina smrzavanja video sekvence uživo postavljena je na 4 sekunde. U svim slučajevima, prve 3 sekunde reprodukcije video sekvence ne uključuju smrzavanje. Tako je dobiveno ukupno 40 degradiranih video sekvenci koje sadrže artefakt smrzavanja okvira (4 za svaku referentnu video sekvencu). Od tih 40 sekvenci, u 10 je smrzavanje okvira posljedica gubitka paketa, dok je u preostalih 30 sekvenci smrzavanje okvira posljedica kašnjenja paketa.

Slika 2.4. prikazuje po jedan okvir svakog referentne video sekvence iz LIVE Mobile baze.

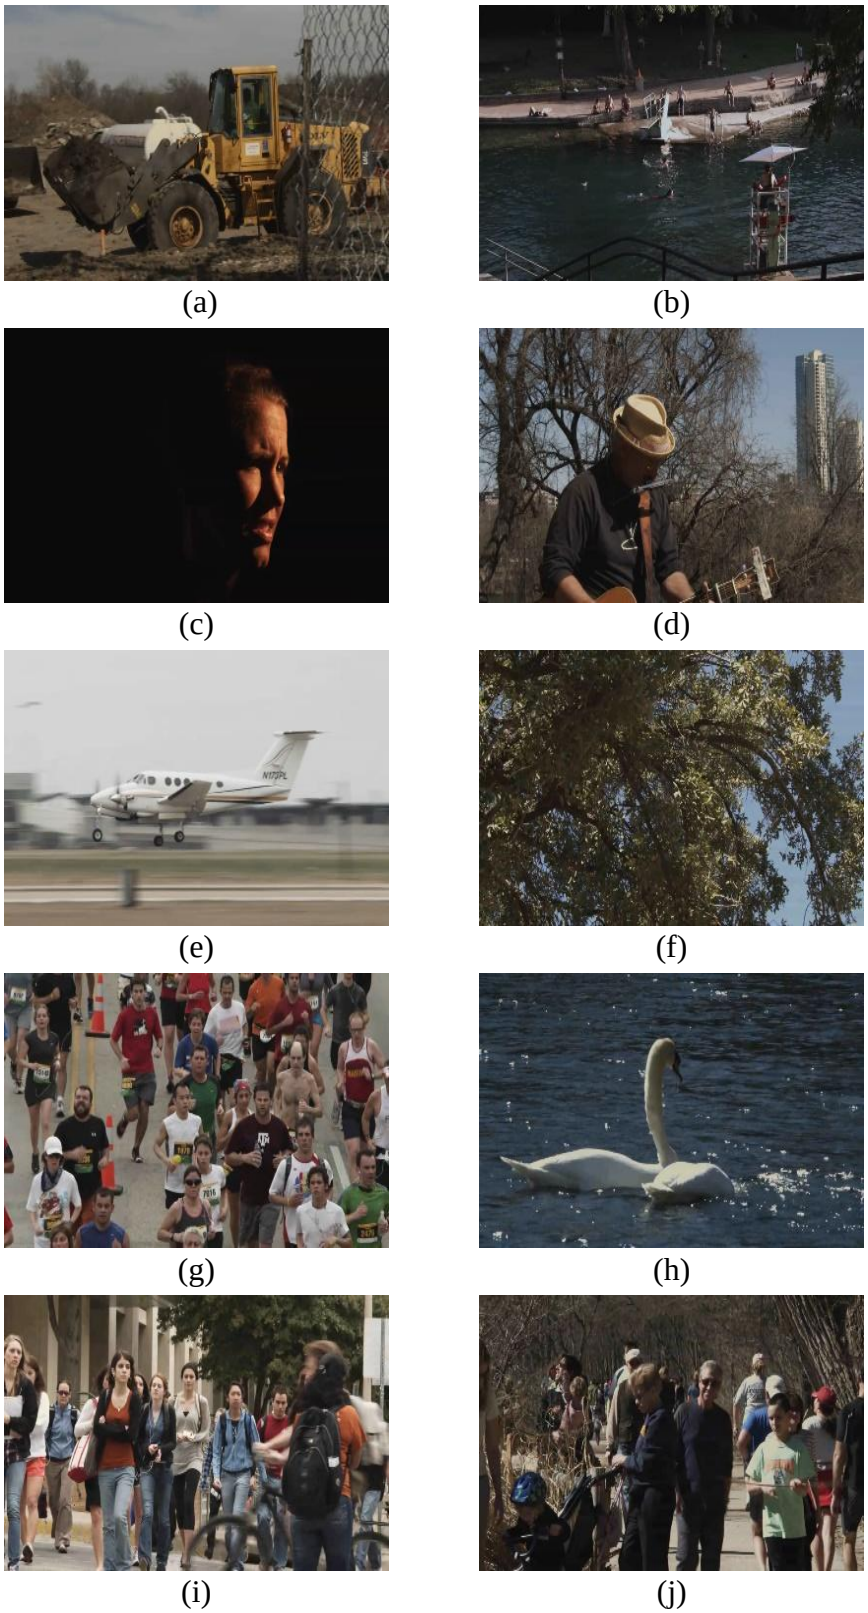

Slika 2.5 Jedan okvir svake korištene referentne video sekvence LIVE Mobile baze (a) *bf*, (b) *dv*, (c) *fc*, (d) *hc* , (e) *la*, (f) *po*, (g) *rb*, (h) *sd*, (i) *ss*, (j) *tk*

2.4.2. VQEG HD baza podataka

VQEG (engl. *Video Quality Experts Group*) HD 5 baza [10] sastoji se od 28 sekvenci koje sadrže artefakt smrzavanja video okvira. U svim je sekvencama smrzavanje okvira uzrokovano gubitkom paketa, no s različitim omjerom gubitka paketa. Ovisno o omjeru gubitka paketa, svaka od 7 izvornih video sekvenci sadrži 4 inačice. Svaka video sekvenca traje 10 sekundi, rezolucija je FullHD (1920x1080), a brzina izmjene okvira je 25 okvira u sekundi. Sekvence su kodirane pomoću H.264 kodera. Pojave artefakata smrzavanja okvira u ovim sekvencama potpuno su nasumične.

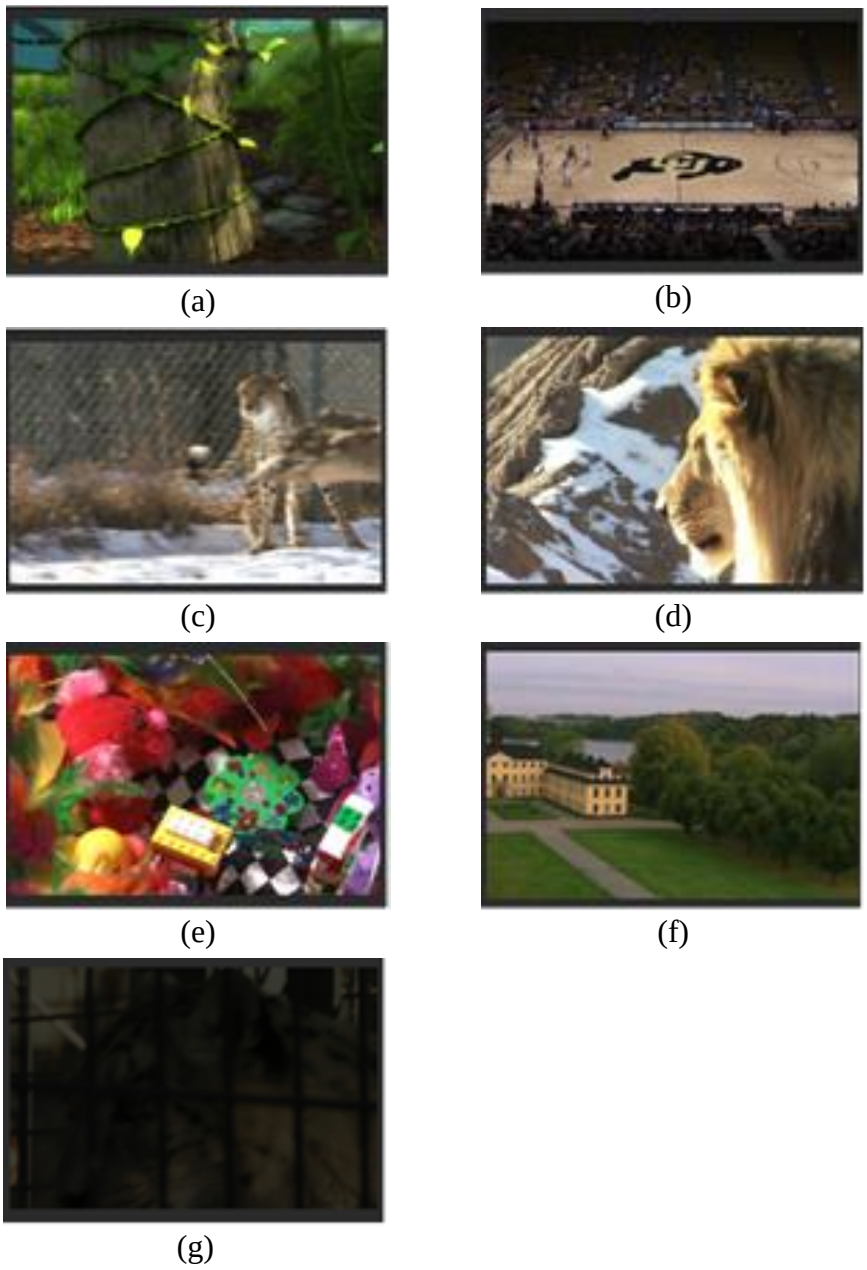

Slika 2.5 Jedan okvir svake korištene referentne video sekvence VQEG HD baze (a)

vqeghd5_src01, (b) *vqeghd5_src02*, (c) *vqeghd5_src04*, (d) *vqeghd5_src05*, (e) *vqeghd5_src06*, (f) *vqeghd5_src08*, (g) *vqeghd5_src09*

2.4.3. FERIT – RTRK UHD VFD baza podataka

FERIT – RTRK UHD VFD baza podataka [5] sastoji od ukupno 26 video sekvenci s prisutnim artefaktom smrzavanja okvira. 13 video sekvenci sadrže artefakt smrzavanja zbog gubitka paketa dok preostalih 13 sadrži artefakt smrzavanja zbog kašnjenja paketa. Sve sekvence kodirane su pomoću H.264 kodera, rezolucija je UHD (3840x2160), brzina izmjene okvira 23,98 okvira u sekundi (za sekvence: *Cactus*, *Coastguard*, *Foreman*, *Mobile*, *News* i *Suzie*) i 20 okvira u sekundi (za sekvence: *Beauty*, *Bosphorus*, *HoneyBee*, *Jockey*, *ReadySetGo*, *ShakeNDry* i *YachtRide*). Svaka degradirana sekvenca ima četiri intervala smrzavanja okvira različitog trajanja (8, 18, 28 i 38 okvira). Ako je uzrok smrzavanja okvira kašnjenje paketa, sekvence imaju konstantne intervale od 50 okvira bez smrzavanja između dva intervala smrzavanja okvira. Ako je uzrok smrzavanja gubitak paketa, interval između dva pojavljivanja smrzavanja okvira može biti 40, 27 i 15 okvira.

Slika 2.6 prikazuje po jedan okvir svakog referentne video sekvence iz FERIT-RTRK UHD VFD baze.

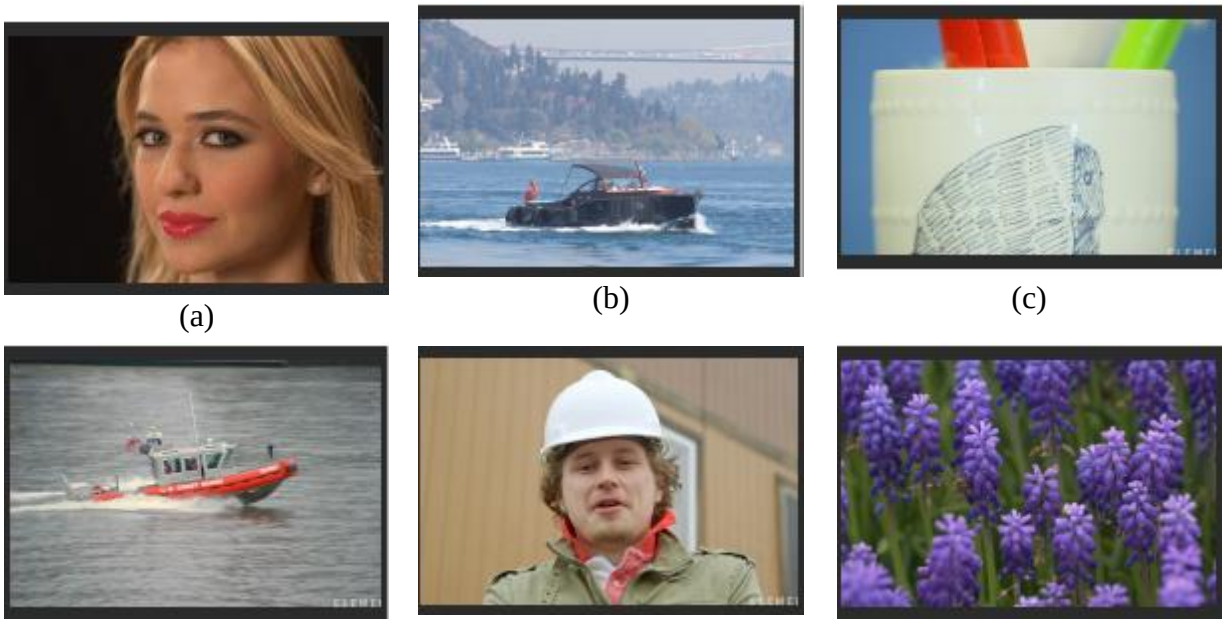

(a) (b) (c)

(d) (e) (f)

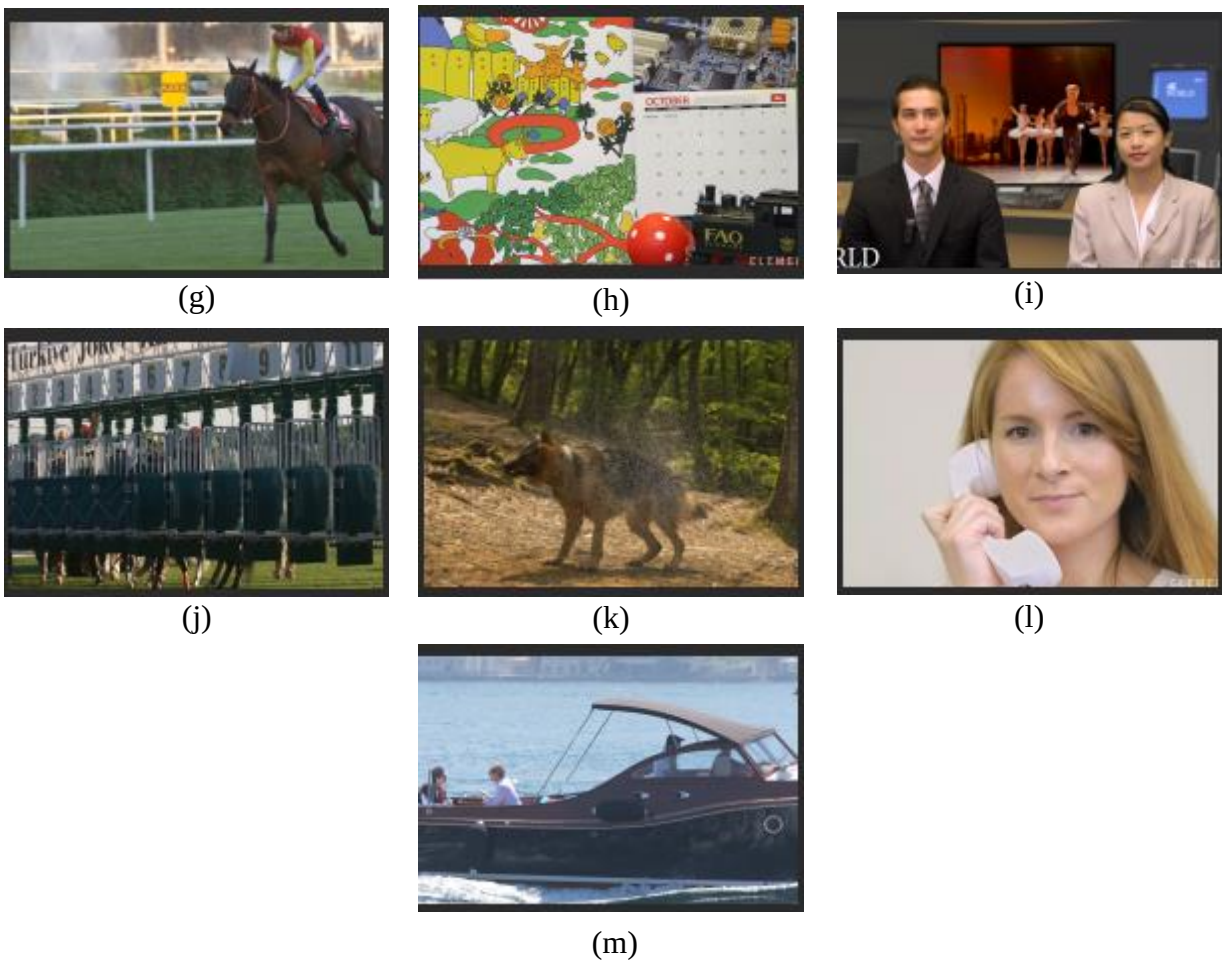

Slika 2.6 Jedan okvir svake korištene referentne video sekvence FERIT-RTRK UHD VFD baze (a) *Beauty*, (b) *Bosphorus*, (c) *Cactus*, (d) *Coastguard*, (e) *Foreman*, (f) *HoneyBee*, (g) *Jockey*, (h) *Mobile*, (i) *News*, (j) *ReadySetGo*, (k) *ShakeNDry*, (l) *Suzie*, (m) *YachtRide*

3. KREIRANA BAZA VIDEO SEKVENCI S PRISUTNIM ARTEFAKTOM SMRZAVANJA

Prethodno opisane baze video sekvenci s prisutnim artefaktom smrzavanja koje su korištene pri testiranju algoritama [5] i [6], pokrivaju širok spektar sadržaja, razlučivosti (HD, FullHD i UHD) i brzine izmjene okvira. Cilj ovog rada je izrada nove baze video sekvenci koja također sadrži artefakt smrzavanja, no čije sekvence nadopunjavaju nedostatke u prethodno proučenim bazama (LIVE Mobile, VQEG HD i FERIT-RTRK UHD VFD baza podataka). Proučavanjem prethodnih baza, uočeno je kako one ne sadrže sporo promjenjive sekvence, stoga je novostvorena baza načinjena od upravo takvih video sekvenci.

Kreirana SMVS (engl. *Slow Motion Video Sequences Database*) FullHD baza podataka sastoji se od ukupno 30 video sekvenci. Referentne sekvence preuzete su s web stranice *Pexels* [11]. Za svaku od ukupno 10 referentnih sekvenci generirana je sekvenca s jednim intervalom smrzavanja trajanja 1 sekundu te sekvenca s dva intervala smrzavanja trajanja 1 i 2 sekunde. Sve video sekvence su FullHD rezolucije, no trajanje i brzina izmjene okvira znatno se razlikuje za svaku sekvencu. Tablicom 3.1. dan je pregled osnovnih parametara referentnih sekvenci.

Tablica 3.1. Pregled osnovnih informacija referentnih sekvenci SMVS FullHD baze

Naziv sekvence	Trajanje [s]	Rezolucija	Broj okvira u sekundi
Ants	22	1920x1080	29.97
CuriousCat	15	1920x1080	60
FlowerVase	12	1080x1920	30
ForestRoad	31	1920x1080	23.98
LightBulb	15	1920x1080	23.98
PaintDrop	15	1080x1920	59.94
Pears	11	1080x1920	25
RelaxedMan	20	1920x1080	50
ShellCandle	8	1080x1920	25
SunsetWalk	19	1920x1080	29.97

U potpoglavlju 3.1. detaljno je opisan sadržaj svake video sekvence novostvorene SMVS FullHD baze, dok potpoglavlje 3.2. donosi prikaz SI-TI karakteristika video sekvenci. Način generiranja artefakta smrzavanja opisan je u potpoglavlju 3.3. Nakon generiranja artefakata smrzavanja, potrebno je potvrditi točan početak i kraj intervala smrzavanja, stoga potpoglavlje 3.4. donosi opis postupka kojim je to potvrđeno.

3.1. Opis video sekvenci SMVS FullHD baze

Video sekvenca *Ants* prikazuje cvijet te nekoliko mrava na njegovim laticama. Najveći dio video sekvence, koju čini pozadina i cvijet, je statičan. Jedina promjena koja se događa u kadru je kretanje mrava po laticama. Na slici 3.2. prikazan je je jedan okvir *Ants* video sekvence.

Slika 3.2. Jedan okvir video sekvence *Ants*

Na početku video sekvence *CuriousCat* prikazani su ključevi na podu, a iz pozadine se može uočiti sjena mačke koja se približava. Približavanje mačke i njena pomalo nejasna sjena čine najveći broj kadrova, dok se na pri kraj video sekvence mačka približi, nakratko pomakne ključeve i nestane iz kadra. Slika 3.3. prikazuje jedan okvir iz video sekvence *CuriousCat*.

Slika 3.3. Jedan okvir iz video sekvence *CuriousCat*

Statična scena na kojoj je prikazana vaza i cvijet dio je video sekvence *FlowerVase*. Primjer jednog okvira prikazan je slikom 3.4., no isti sadržaj prikazuje se gotovo kroz cijeli video. Okviri se jedino razlikuju kada dođe do pomicanja latica cvijeta.

Slika 3.4. Jedan okvir iz video sekvence *FlowerVase*

Video sekvenca *ForestRoad* prikazuje cestu koja prolazi kroz šumu. Sporu promjenu u video sekvenci čini sporo kretanje automobila. Jedan okvir video sekvence *ForestRoad* prikazan je slikom 3.5.

Slika 3.5. Jedan okvir iz video sekvence *ForestRoad*

LightBulb video sekvenca prikazuje žarulju na snijegu. Sekvenca ne sadrži kretanje, a jedina razlika između okvira je prilikom promjene intenziteta svjetline koja se može primijetiti na grlu žarulje. Slikom 3.6. prikazan je primjer jednog okvira video sekvence *LightBulb*.

Slika 3.6. Jedan okvir video sekvence *LightBulb*

Sljedeća video sekvenca, naziva *PaintDrop*, prikazuje posudu s bojom na koju je prislonjen kist s kojeg povremeno padne kapljica boje. Ne dolazi do promjene scene, a formiranje kapljice predstavlja izuzetno sporu promjenu. Jedan okvir video sekvence *PaintDrop* prikazan je slikom 3.7.

Slika 3.7. Jedan okvir video sekvence *PaintDrop*

Dvije kruške i drveni objekt sadržaj su video sekvence *Pears*. Kao i kod video sekvence *LightBulb*, i ova sekvenca ne sadrži nikakve pokrete, nego samo pojedinim intenziteta svjetline na pojedinim dijelovima okvira. Slikom 3.8. prikazan je primjer jednog okvira video sekvence *Pears*.

Slika 3.8. Jedan okvir video sekvence *Pears*

Na video sekvenca *RelaxedMan* teško je uočiti kretanje. Pozadina je nepromijenjena, a osoba koja sjedi u fotelji nalazi se u polumraku. Jedina promjena koja se događa je kretanje očiju, a primjer jednog okvira dan je slikom 3.9.

Slika 3.9. Jedan okvir video sekvence *RelaxedMan*

Iduća video sekvenca prikazuje čašu i svijeću na stolu, dok se u pozadini nalazi zid na kojem je slika. Svi objekti su nepomični tijekom cijele video sekvence, a fokus je na svijeći. Svijeća na početku gori, zatim biva ugašena, a u preostalom dijelu sekvence prisutan je dim. To su jedine promjene koje se događaju između okvira. Slika 3.10. prikazuje jedan okvir *ShellCandle* video sekvence.

Slika 3.10. Jedan okvir video sekvence *ShellCandle*

Zadnja video sekvenca u bazi nosi naziv *SunsetWalk*. Prikazuje osobu koji se vrlo sporo približava iz daljine. Osobu je na početku vrlo teško razaznati, jer ju zaklanja zalazak sunca u pozadini. Primjer okvira iz video sekvence *SunsetWalk* dan je slikom 3.11.

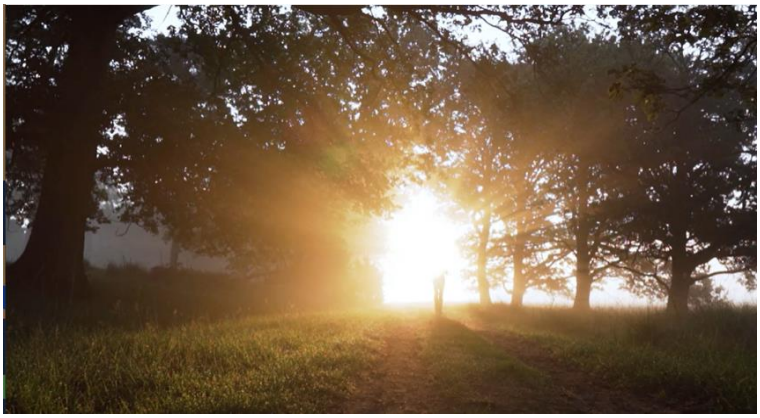

Slika 3.11. Jedan okvir video sekvence *SunsetWalk*

3.2. SI-TI karakteristike video sekvenci SMVS FullHD baze

Pri izradi baze podataka za testiranje algoritma potrebne su video sekvence različitog sadržaja, odnosno sekvence koje sadrže različite vrijednosti i kombinaciju prostorno-vremenskih aktivnosti. Prostorne i vremenske aktivnosti mogu se izračunati koristeći *Spatial perceptual Information* (SI) i *Temporal perceptual Information* (TI) kao što je dano u ITU-T P.910 preporuci.

SI predstavlja mjeru koja ukazuje na količinu prostornih detalja na slici. Ukoliko je scena složenija, vrijednost će biti veća. Proračun SI vrijednosti temelji se na Sobelovom filtru. Svaki okvir videosignala F_n se filtira Sobelovim filtrom [$Sobel(F_n)$]. Zatim se računa standardna devijacija za svaki okvir filtriran Sobelovim filtrom, $std[Sobel(F_n)]$. Standardna devijacija predstavlja korijen sume kvadrata razlike između trenutne vrijednosti elementa slike i srednje vrijednosti elementa slike. Ta se operacija ponavlja za svaki okvir u video sekvenci i rezultira vremenskim nizom prostornih informacija scene. Maksimalna vrijednost u vremenskom nizu (max_{time}) predstavlja *Spatial perceptual Information*:

$$SI = max_{time}\{std_{space}[Sobel(F_n)]\} \tag{3-1}$$

TI je mjera koja pokazuje količinu vremenskih promjena unutar video sekvence. Poprima veće vrijednosti ukoliko scena sadrži veću količinu pokreta. Prvo se računa razlika između vrijednosti elemenata slike (luminantna komponenta) na istom mjestu u prostoru, ali u uzastopnim kadrovima, $M_n(i, j)$:

$$M_n(i,j) = F_n(i,j) - F_{n-1}(i,j) \tag{3-2}$$

gdje $F_n(i, j)$ element slike u i-tom retku i j-tom stupcu n-tog okvira.

Za dobivene vrijednosti okvira razlike $M_n(i, j)$ računa se standarda devijacija, $std[M_n(i, j)]$. Standardna devijacija računa se za svaki okvir, a maksimalna vrijednost standardne devijacije duž cijelog videosignala predstavlja TI:

$$TI = max_{time}\{std_{space}[M_n(i,j)]\} \tag{3-3}$$

Tablicom 3.2. prikazane su vrijednosti SI i TI svake pojedine sekvence SMVS FullHD baze, dok je slikom 3.1. dan grafički prikaz ovisnosti te dvije vrijednosti.

Tablica 3.2. SI i TI vrijednosti sekvenci SMVS FullHD baze

Ime video sekvence	SI	TI
Ants	23.121	0.586
CuriousCat	9.749	1.797
FlowerVase	28.409	0.982
ForestRoad	45.948	1.35
LightBulb	20.211	1.234
PaintDrop	26	0.558

Pears	30.206	1.2
RelaxedMan	39.838	0.434
ShellCandle	13.579	0.573
SunsetWalk	70.906	0.527

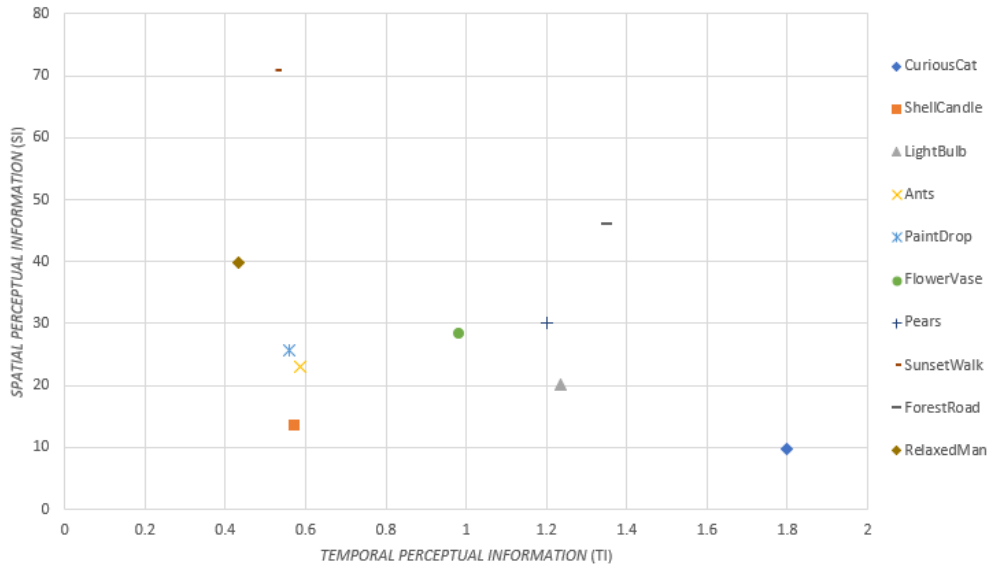

Slika 3.1. Grafički prikaz prostorno-vremenske aktivnosti video sekvenca

Sve video sekvence imaju vrlo male vrijednosti TI, što ukazuje na malu količinu vremenskih promjena unutar cjelokupne video sekvence. Najmanja vrijednost iznosi 0.43, video sekvence *Relaxedman*, a uzrok tako male vrijednosti je gotovo nikakvo kretanje tijekom cijelog trajanja video sekvence. Cijela scena je stacionarna, a jedine promjene događaju se povremeno na malom dijelu okvira (pomak očiju, mali pomak tijela zbog udisaja/izdisaja). Video sekvence *SunsetWalk*, *PaintDrop*, *Ants* i *ShellCandle* imaju gotovo jednake vrijednosti TI (od 0.527 do 0.586), no i dalje sadrže vrlo malo promjena tijekom vremena. Veće vrijednosti TI počinju od video sekvence *FlowerVase* koja sadrži neprestano kretanje na manjem dijelu video okvira. Najveću vrijednost TI ima video sekvenca *CuriousCat* 1.797. Iako je na samom početku video sekvence *CuriousCat* promjena scene neznatna i teško uočljiva, u drugom dijelu dolazi do naglih pokreta (kretanje mačke prema kameri) što je uzrok povećanja vrijednosti vremenske aktivnosti - TI.

SI obuhvaća širi spektar vrijednosti ukazujući na raznolikost sadržaja cjelokupne baze. Najmanju vrijednost 9.749 ima video sekvenca *CuriousCat* jer scena ne sadrži veću količinu detalja (pod, ključevi, pozadina i mačka). Najveću vrijednost SI 70.906 ima video sekvenca *SunsetWalk* koja sadrži mnogo prostornih detalja koje stvaraju krošnje drveća i trava.

SMVS FullHD baza sadrži video sekvence koje uključuju kombinacije niske vrijednosti TI i visoke vrijednosti SI, kao i visoke vrijednosti TI i niske vrijednosti SI. Takvim TI- SI ovisnostima pokrivene su sve kombinacije prostorne i vremenske aktivnosti, a time je omogućeno da SMVS FullHD baza bude vjerodostojnija u procesu testiranja algoritama.

3.3. Generiranje artefakta smrzavanja

Artefakt smrzavanja generiran je pomoću *ffmpeg*-a [12]. Smrzavanje nastaje kao posljedica ponavljanja istog okvira zadani vremenski period. U nastavku je prikazana naredba kojom se generira smrzavanje:

ffmpeg -i input -vf "setpts='PTS-STARTPTS + gte(T,start1)(duration/TB) + gte(T,start2)*(duration/TB)'" output*

gdje je: *input* putanja do referentne video sekvence, *setpts=PTS-STARTPTS* počinje brojati PTS (vremenska oznaka prezentacije) od nule, *T* vrijeme u sekundama trenutnog okvira, *start1* i *start2* vrijeme početka intervala smrzavanja, *duration* trajanje intervala smrzavanja, *output* putanja novo generirane video sekvence s prisutnim artefaktom smrzavanja.

Navedenom naredbom generira se video sekvenca koja sadrži dva intervala smrzavanja. Smrzavanje se postiže ponavljanjem istog okvira zadani vremenski period.

3.4. Potvrda artefakta smrzavanja

Nakon što se uspješno generira smrzavanje, potrebno je potvrditi njegovo postojanje, odnosno točan okvir koji predstavlja početak i okvir koji predstavlja kraj intervala smrzavanja.

Za potvrdu smrzavanja korišten je *ffmpeg* filtar *freezedetect* [13]. Detekcija smrzavanja video sekvenci temelji se na izračunavanju srednje prosječne apsolutne razlike svih komponenti video okvira te zatim uspoređivanju s minimalnim šumom. U nastavku je prikazana *freezedetect* naredba:

ffmpeg -i input -vf "freezedetect=n=-60dB:d=2,metadata=mode=print:file=filename.txt" -map 0:v:0 -f null -

gdje *input* predstavlja putanju do video sekvence u kojoj se želi detektirati artefakt smrzavanja, *n* predstavlja dozvoljenu razinu šuma (ukoliko je izražena u dB, zadana vrijednost je -60dB), *d* predstavlja najmanje trajanje smrzavanja nakon kojeg se detektira kao takvo. Ovom se naredbom

detektira smrzavanje, a dobivene vrijednosti zapisuju se u *.txt* datoteku. Ispisane vrijednosti početka, kraja i intervala smrzavanja izraženi su u sekundama.

Dobivene vrijednosti su:

- *lavfi.freezedetect.freeze_start* – postavljena je na prvi okvir čija je vremenska oznaka jednaka ili premašuje trajanje detekcije (*d*) i sadrži vremensku oznaku prvog okvira smrzavanja
- *lavfi.freezedetect.freeze_duration* – predstavlja trajanje intervala smrzavanja
- *lavfi.freezedetect.freete_end* – predstavlja zadnji okvir u intervalu smrzavanja

Sve dobivene vrijednosti izražene u sekundama pomnožene su s brzinom izmjene okvira trenutno testirane video sekvence, kako bi se dobila vrijednost početnog i krajnjeg okvira jer oba algoritma na kojima se baza testira, procjenu točnosti detekcije temelje na broju okvira, a ne na vrijednosti izraženoj u sekundama.

Pri pojavi artefakta smrzavanja, apsolutna razlika luminantne komponente prethodnog i ponovljenog okvira bila bi 0, što znači da su okviri identični. Na slici 3.2. (a, b) prikazana je apsolutna razlika luminantne komponente dvaju uzastopnih okvira za slučaj kada nema smrzavanja i kada je pristupno smrzavanje. Potpuno crna slika pokazatelj je identičnosti okvira, odnosno pojave smrzavanja.

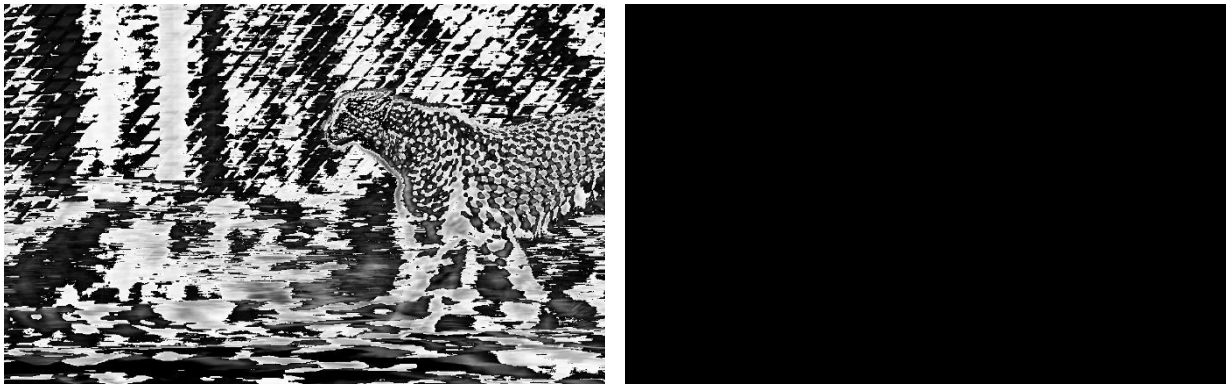

(a) (b)

Slika 3.2. Apsolutna razlika luminantne komponente dvaju uzastopnih okvira: (a) bez smrzavanja, (b) pri smrzavanju

Prilikom reprodukcije video sekvenci, sustav za reprodukciju (dohvaćanje) unosi šum u ponovljene okvire te okviri više nisu potpuno isti. Slikom 3.3. (a, b) prikazana je razlika luminantne komponente dvaju uzastopnih za slučaj kada nema smrzavanja i kada je pristupno smrzavanje. U ovom slučaju kada dođe do pojave smrzavanja ponovljeni okviri nisu identični zbog pojave šuma koji je vidljiv na slici 3.3. (b).

(a) (b)

Slika 3.3. Apsolutna razlika luminantne komponente dvaju uzastopnih okvira: (a) bez smrzavanja, (b) pri smrzavanju

Kako je novostvorena baza kreirana od video sekvenci koje sadrže vrlo spore promjene, apsolutna razlika luminantne komponente dvaju uzastopnih okvira za slučaj kada je prisutno smrzavanje i kada nije gotovo je ista. Slikom 3.4. (a, b) prikazana je razlika luminantne komponente dvaju uzastopnih za slučaj kada nema smrzavanja i kada je pristupno smrzavanje za video sekvencu *LightBulb1x* iz novostvorene SMVS FullHD baze.

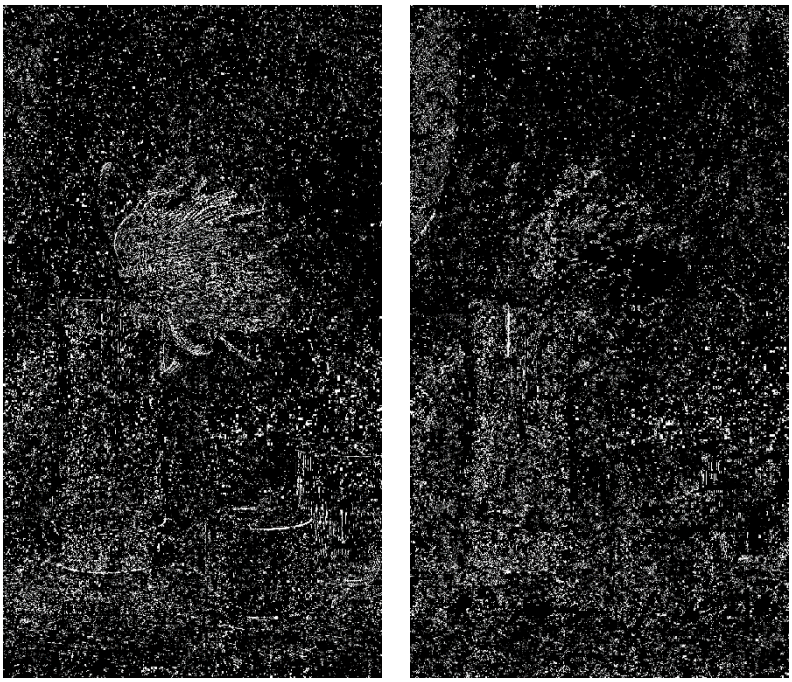

(a) (b)

Slika 3.4. Apsolutna razlika luminantne komponente dvaju uzastopnih okvira video sekvence *LightBulb1x*: (a) bez smrzavanja, (b) pri smrzavanju

4. EVALUACIJA I VERIFIKACIJA DOSTUPNIH ALGORITAMA ZA DETEKCIJU ARTEFAKATA SMRZAVANJA NA NOVOSTVORENOJ BAZI PODATAKA

U ovom poglavlju opisan je proces verifikacije rada predloženih algoritama [5] i [6] te njihova evaluacija na javno dostupnim i prethodno opisanim bazama podataka: LIVE Mobile, VQEG HD i FERIT-RTRK UHD VFD bazi podataka. HBFDA algoritam iz [5] implementiran je u C++ programskom jeziku, dok je implementacija RTFDA algoritma iz [6] dana u Python programskom jeziku. Oba algoritma testirana su na ukupno 94 video sekvence s prisutnim artefaktom smrzavanja (40 video sekvenci iz baze LIVE Mobile, 28 video sekvenci iz VQEG HD baze i 26 video sekvenci iz baze FERIT-RTRK UHD VFD).

Ispravna implementacija algoritama potvrđena je na način da su algoritmi izvršeni nad sekvencama nad kojima su se izvršili u izvornim radovima s ciljem dobivanja istih rezultata koji su dobiveni u radovima.

Kako bi se ocijenila učinkovitost pojedinog algoritma, koristi se sljedeće:

- TP (engl. *True postive)* – okvir koji je dio intervala smrzavanja i koje je algoritam uspješno detektirao kao smrzavanje;
- TN (engl. *True negative*) – okvir koji nije dio intervala smrzavanja i koji je algoritam uspješno detektirao kao takav;
- FP (engl. *False positive*) – okvir koji nije dio intervala smrzavanja, ali ga je algoritam pogrešno detektirao kao smrzavanje;
- FN (engl. *False negative*) – okvir koji je dio intervala smrzavanja, ali ga je algoritam pogrešno detektirao kao ne smrzavanje;

Na temelju dobivenih vrijednosti TP, TN, FP i FN moguće je izračunati sljedeće parametre kojima se potvrđuje uspješnost pojedinog algoritma: preciznost, odziv, F1 i točnost.

Preciznost (engl. *precission*) je definirana kao omjer između broja pozitivnih uzoraka koji su ispravno klasificirani i ukupnog broja uzoraka koji su klasificirani kao pozitivni (točni ili netočni) (4-1). U idealnom slučaju preciznost bi trebala bit 1, a to se događa ukoliko su brojnik i nazivnih jednaki., tj. TP = TP+FP, što znači da bi vrijednost FP trebala biti 0. Kako vrijednost FP raste, vrijednost nazivnika postaje veća od vrijednosti brojnika te se preciznost smanjuje.

$$Preciznost = \frac{TP}{TP + FP} \tag{4-1}$$

Odziv (engl. *recall*) predstavlja omjer između broja pozitivnih uzoraka koji su uspješno klasificirani kao pozitivni i ukupnog broja pozitivnih uzoraka (4-2). Kada model klasificira sve pozitivne uzorke kao pozitivne, tada će odziv biti 100% čak i ako su svi negativni uzorci netočno klasificirani kao pozitivni.

$$Odziv = \frac{TP}{TP + FN} \tag{4-2}$$

F1 je mjera koja predstavlja ravnotežu između preciznosti i odziva. Stoga su u proračun uključeni i lažno pozitivni i lažno negativni rezultati.

$$F1 = 2 * \frac{Preciznost * Odziv}{Preciznost + Odziv} \tag{4-3}$$

Točnost (engl. *accuracy*) je mjera koja predstavlja sve točno detektirane vrijednosti u ukupnom skupu detektiranih vrijednosti.

$$Točnost = \frac{TP + TN}{TP + FP + FN + TN} \tag{4-4}$$

4.1. Rezultati algoritama nad SMVS FullHD bazi podataka

Nakon izrade SMVS FullHD baze koja se sastoji od 30 video sekvenci, testirana je točnost oba algoritma, a rezultati su prikazani u nastavku. 1x u nazivu video sekvence označava da sadrži jedan interval smrzavanja, dok 2x u nazivu označava dva intervala smrzavanja.

Tablica 4.1. Rezultati testiranja HBFDA algoritma nad video sekvencama s prisutnim jednim intervalom smrzavanja SMVS FullHD baze podataka

Ime video sekvence	TP	TN	FP	FN	Preciznost	Odziv	F1	Točnost
Ants1x	37	2	651	0	0.053779	1	0.102069	5.6522%
CuriousCat1x	63	591	305	0	0.171196	1	0.292343	68.1960%
FlowerVase1x	38	297	68	1	0.358491	0.974359	0.524138	82.9208%
ForestRoad1x	24	331	434	0	0.052402	1	0.099585	44.9937%
LightBulb1x	23	368	2	1	0.92	0.958333	0.938776	99.2386%

PaintDrop1x	62	147	770	0	0.074519	1	0.138702	21.3483%
Pears1x	24	290	2	2	0.923077	0.923077	0.923077	98.7421%
RelaxedMan1x	58	295	695	0	0.077025	1	0.143033	33.6832%
ShellCandle1x	35	22	169	0	0.171569	1	0.292887	25.2212%
SunsetWalk1x	32	6	589	0	0.05153	1	0.098009	6.0606%
UKUPNO	**396**	**2349**	**3685**	**4**	**0.09704**	**0.99**	**0.176746**	**42.66%**

Tablicom 4.1. prikazani su dobiveni rezultati nad SMVS FullHD bazom korištenjem HBFDA algoritma. Preciznost nad cijelom bazom iznosi 0.09704, što znači da je uz pozitivne okvire detektirano i puno neispravnih, negativnih okvira. S druge strane, odziv je vrlo visok, s iznosom 0.99, što znači da je algoritam uspješno detektirao okvire koji su dio smrzavanja. Kako u proračun mjere F1 ulaze dobivene vrijednosti preciznosti i odziva, zbog vrlo male vrijednosti preciznosti, mjera F1 također je vrlo niska. Ukupna točnost nad svim video sekvencama baze iznosi 42.66%, što je za razliku od rezultata HBFDA algoritma nad bazama LIVE Mobile, VQEG HD i FERIT-RTRK UHD VFD, vrlo loš rezultat.

Tablica 4.2. Rezultati testiranja RTFDA algoritma nad video sekvencama s jednim intervalom smrzavanja SMVS FullHD baze podataka

Ime video sekvence	TP	TN	FP	FN	Preciznost	Odziv	F1	Točnost
Ants1x	29	613	42	8	0.408451	0.783783784	0.53703704	92.775%
CuriousCat1x	63	834	64	0	0.496063	1	0.66315789	93.340%
FlowerVase1x	29	327	40	10	0.42029	0.743589744	0.53703704	87.685%
ForestRoad1x	24	754	13	0	0.648649	1	0.78688525	98.357%
LightBulb1x	23	230	142	1	0.139394	0.958333333	0.24338624	63.889%
PaintDrop1x	61	701	218	1	0.218638	0.983870968	0.35777126	77.676%
Pears1x	26	247	47	0	0.356164	1	0.52525253	85.313%
RelaxedMan1x	51	874	118	7	0.301775	0.879310345	0.44933921	88.095%
ShellCandle1x	24	142	51	11	0.32	0.685714286	0.43636364	72.807%
SunsetWalk1x	32	266	331	0	0.088154	1	0.16202532	47.377%
UKUPNO	**362**	**4988**	**1066**	**38**	**0.253501**	**0.90500**	**0.39606**	**82.89%**

U tablici 4.2. prikazani su rezultati testiranja RTFDA algoritma nad SMVS FullHD bazom podataka. Preciznost je nešto bolja od preciznosti algoritma HBFDA u tablici 4.1, i iznosi 0.253501 te je automatski i vrijednost F1 veća od vrijednosti dobivene korištenjem HBFDA algoritma. Odziv je nešto manji i iznosi 0.90500, no i dalje se može zaključiti da algoritam uspješno detektira stvarna smrzavanja. Točnost je, s druge strane, znatno veća te iznosi 82.89%.

Tablica 4.3. Rezultati testiranja HBFDA algoritma nad video sekvencama s dva intervala smrzavanja SMVS FullHD baze podataka

Ime video sekvence	TP	TN	FP	FN	Preciznost	Odziv	F1	Točnost
Ants2x	95	2	653	0	0.127005	1	0.225386	12.9333%
CuriousCat2x	178	519	378	4	0.320144	0.978022	0.482385	64.5968%
FlowerVase2x	98	299	65	2	0.601227	0.98	0.745247	85.5603%
ForestRoad2x	72	338	427	0	0.144289	1	0.252189	48.9845%
LightBulb2x	72	365	2	3	0.972973	0.96	0.966443	98.8688%
PaintDrop2x	160	114	825	0	0.162437	1	0.279476	24.9318%
Pears2x	73	261	4	30	0.948052	0.708738	0.811111	90.7609%
RelaxedMan2x	161	360	620	7	0.206146	0.958333	0.339305	45.3833%
ShellCandle2x	79	22	175	0	0.311024	1	0.474474	36.5942%
SunsetWalk2x	96	6	585	0	0.140969	1	0.247104	14.8472%
UKUPNO	**1084**	**2286**	**3734**	**46**	**0.22499**	**0.959292**	**0.364492**	**47.13%**

Tablica 4.4. Rezultati testiranja RTFDA algoritma nad video sekvencama s dva intervala smrzavanja SMVS FullHD baze podataka

Ime video sekvence	TP	TN	FP	FN	Preciznost	Odziv	F1	Točnost
Ants2x	84	609	48	11	0.63636364	0.88421053	0.7400881	92.154%
CuriousCat2x	178	829	70	4	0.71774194	0.97802198	0.827907	93.154%
FlowerVase2x	88	325	41	12	0.68217054	0.88	0.768559	88.627%
ForestRoad2x	70	756	11	2	0.86419753	0.97222222	0.9150327	98.451%
LightBulb2x	75	235	134	0	0.35885167	1	0.528169	69.820%
PaintDrop2x	159	689	252	1	0.38686131	0.99375	0.5569177	77.021%
Pears2x	80	225	42	23	0.6557377	0.77669903	0.7111111	82.432%
RelaxedMan2x	156	869	113	12	0.57992565	0.92857143	0.7139588	89.130%
ShellCandle2x	73	151	48	6	0.60330579	0.92405063	0.73	80.576%
SunsetWalk2x	96	268	325	0	0.2280285	1	0.3713733	52.830%
UKUPNO	**1059**	**4956**	**1084**	**71**	**0.49416706**	**0.937168**	**0.647113**	**83.89%**

Rezultati koji su dobiveni za video sekvence s dva intervala smrzavanja potvrđuju rezultate koji su dobiveni za video sekvence s jednim intervalom smrzavanja. Točnost se razlikuje za nekoliko posto, no preciznost se povećava. Kako oba algoritma detektiraju intervale smrzavanja duž gotovo cijele video sekvence, povećanjem broja intervala stvarnog smrzavanja, raste vjerojatnost da će ih algoritam detektirati.

Kada se usporede oba algoritma, bolje rezultate daje RTFDA algoritam. Iako oba algoritma uspješno prepoznaju stvarna smrzavanja, RTFDA bolje detektira okvire koji nisu dio smrzavanja – TN, dok HBFDA algoritam daje mnogo više lažnih detekcija – FP, što ga čini nepouzdanim i manje točnim. Rezultat detekcije mnogo FP okvira rezultira manjom preciznošću, a kako

preciznost ulazi u proračun mjere F1, tako je i njena vrijednost manja. Video sekvence kao što su: *Ants*, *PaintDrop*, *RelaxeMan* i *SunsetWalk* predstavljaju najveći problem prilikom detekcije HBFDA algoritmu što je vidljivo po broju FP okvira. Razlog tomu je vrlo mala količinu vremenskih promjena unutar video sekvence. Promjene koje su prisutne su neznatne i teško uočljive, što navodi algoritam na detekciju smrzavanja iako ono nije prisutno.

Kako bi se jasnije prikazao način detekcije smrzavanja okvira, tablicom 4.5. i 4.6. prikazani su intervali koje algoritmi [5] i [6] detektiraju kao smrzavanje. PO predstavlja prvi okvir u intervalu smrzavanja, dok KO predstavlja krajnji okvir u intervalu.

Tablica 4.5. Rezultati detekcije intervala smrzavanja HBFDA i RTFDA algoritma nad video sekvencama SMVS FullHD baze podataka s prisutnim jednim intervalom smrzavanja

Ime video sekvence	**Stvarna smrzavanja: PO-KO**	**Detekcija HBFDA algoritma: PO- KO**	**Detekcija RTFDA algoritma: PO-KO**
Ants1x	569-605	3-690	84- 88, 138- 145, 185- 189, 439- 451, 571- 599, 662- 666, 687- 692
CuriousCat1x	299-361	3-184, 272-421, 669-704	237- 245, 266- 365, 363- 367, 369- 379, 385- 389
FlowerVase1x	150-188	41-92, 120-133, 151- 190	48- 52, 53- 57, 63- 67, 78- 82, 92- 96, 97- 106, 115- 119, 151- 179
ForestRoad1x	504-527	88- 109, 157- 174, 185- 192, 207- 283, 299- 310, 319- 406, 426- 446, 504- 535, 555- 560, 566- 621, 639- 646, 662- 700, 704- 759, 775- 789	504- 529, 554- 559, 566- 570
LightBulb1x	264-287	265-289	12- 23, 41- 46, 62- 82, 120- 125, 139- 144, 158- 165, 185- 189, 199- 204, 211- 219, 221- 232, 247- 256, 265- 289, 291- 297, 309- 320, 345- 351, 356- 360, 364- 371
PaintDrop1x	420-481	112- 887, 924- 979	195- 199, 203- 256, 333- 366, 367- 371, 379- 383, 421- 481, 521- 531, 560- 566, 569- 573, 625- 645, 669- 685, 689-713, 737- 750, 779- 783, 918- 928
Pears1x	149-174	151- 176	70-74, 95-102, 144-177, 196- 200, 223- 228, 242- 246, 307- 316
RelaxedMan1x	251-308	7- 166, 186- 496, 585- 672, 723- 760, 802- 910, 1002- 1048	3- 8, 42- 46, 94- 98, 121- 128, 178- 190, 236- 240, 248- 301, 314- 322, 450- 457, 568- 573, 577- 583, 586- 596, 725- 730, 736- 740, 942- 946, 996- 1002, 1018- 1026
ShellCandle1x	98-132	23- 226	2- 30, 56- 62, 80- 94, 101- 124
SunsetWalk1x	148-179	7- 627	2- 85, 86- 93, 99- 103, 106- 124, 127- 131, 148- 182, 253- 273, 289- 341, 345- 349, 355- 366, 367- 376, 379- 408, 428- 450, 476- 486, 504- 514, 573- 583, 586- 590, 600- 614

Tablica 4.6. Rezultati detekcije intervala smrzavanja HBFDA i RTFDA algoritma nad video sekvencama SMVS FullHD baze podataka s prisutna dva intervala smrzavanja

Ime video sekvence	Stvarna smrzavanja: PO- KO	Detekcija HBFDA algoritma: PO- KO	Detekcija RTFDA algoritma: PO- KO
Ants2x	179- 212, 547- 607	3- 750	84- 88, 138- 145, 181- 211, 469- 481, 540- 599, 723- 727, 736- 740, 746- 750
CuriousCat2x	178- 299, 720- 779	3- 177, 181- 481, 721- 779, 806- 826	181- 299, 354- 358, 357- 365, 386- 425, 423- 427, 429- 433, 431- 439, 445- 449, 721- 779
FlowerVase2x	85- 119, 300- 364	41- 121, 173- 191, 301- 363	48- 52, 53- 57, 63- 67, 78- 82, 91- 119, 121- 126, 127- 132, 131- 136, 145- 149, 301- 359
ForestRoad2x	360- 383, 576- 623	88- 109, 157- 174, 185- 192, 207- 283, 299- 310, 326- 430, 452- 470, 555- 561, 566- 677, 681- 734, 756- 781, 785- 807, 822- 837	361- 383, 554- 559, 566- 570, 577- 623
LightBulb2x	72- 121, 263- 287	73- 121, 265- 289	12- 23, 41- 46, 62- 130, 168- 172, 188- 192, 206- 213, 233- 237, 247- 251, 257- 290, 293- 303, 320- 328, 339- 345, 357- 368, 393- 399, 404- 408, 412- 420
PaintDrop2x	353- 419, 658- 750	112- 947, 951- 1099	195- 199, 203- 256, 333- 337, 339- 433, 441- 445, 521- 531, 560- 566, 569- 573, 625- 633, 635- 645, 659- 783, 785- 806, 812- 828, 843- 847, 858- 871, 899- 903, 957- 961, 1038- 1049
Pears2x	48- 99, 174- 224	76- 101, 176- 226	70- 74, 76- 99, 120- 127, 169- 227, 246- 250, 273- 278, 292- 296, 357- 366
RelaxedMan2x	251- 308, 593- 702	7- 166, 186- 496, 600- 784, 788- 860, 1097- 1148	3- 8, 42- 46, 94- 98, 121- 128, 178- 190, 236-240, 248- 301, 314- 322, 450- 457, 577- 596, 599- 699, 825- 830, 836- 841, 1042- 1046, 1096- 1103, 1117- 1126
ShellCandle2x	50- 74, 174- 227	23- 276	2- 30, 51- 74, 81- 87, 107- 118, 176- 224
SunsetWalk2x	148- 179, 330- 393	7- 687	2- 93, 99- 124, 127- 131, 148- 182, 253- 273, 289- 401, 405- 409, 415- 436, 440- 467, 489- 510, 536- 546, 565- 574, 635- 643, 646- 650, 652- 656, 660- 673

Iz tablica 4.3. i 4.4. može se uočiti kako RTFDA algoritam detektira više intervala smrzavanja, no intervali su znatno kraći od intervala koje detektira HBFDA algoritam. HBFDA algoritam detektira duže intervale, koji vrlo često obuhvaćaju veliki dio video sekvence. Oba algoritma većinom uspješno detektiraju stvarne intervale smrzavanja, no popratno detektiraju i „lažna

smrzavanja“. Veću uspješnost pri detekciji pokazuje RTFDA algoritam jer on, za razliku od HBFDA, detektira više TN okvira, odnosno uspješno detektira okvire koji nisu dio intervala smrzavanja kao takve. Vidljivo je kako za video sekvence *Ants* i *SunsetWalk* HBFDA algoritam detektira jedan interval smrzavanja koji obuhvaća cijeli interval trajanja video sekvence, dok za video sekvence kao što su: *ForestRoad*, *PaintDrop* i *RelaxeMan* detektira nekoliko intervala smrzavanja koji uzastopno slijede jedan drugog. Takav način detekcije razlog je vrlo loših rezultata detekcije HBFDA algoritma i mnogo lažno pozitivnih okvira.

5. ZAKLJUČAK

Kvaliteta video sekvenci od temeljne je važnosti za brojne aplikacije koje obrađuju sliku i video. Jedan od najčešćih artefakata koji se pojavljuje je artefakt smrzavanja slike. Javlja se prilikom prijenosa video sekvence, koja je podijeljena na pakete, prijenosnim kanalom uslijed kojeg može doći do gubitka ili ispuštanja paketa. Smrzavanje se manifestira ponavljanjem posljednjeg ispravnog prenesenog okvira, sve dok sljedeći ispravno preneseni okvir ne bude primljen, a pri tome može doći do preskakanja okvira ili do nastavka reprodukcije video sekvence, ovisno o tipu smrzavanja. Kako bi se smanjio utjecaj smrzavanja slike na njihovu kvalitetu, kreirani su algoritmi koji detektiraju artefakt smrzavanja. Uspješnost detekcije algoritama testirana je na bazama video sekvenci s prisutnim artefaktom smrzavanja.

Proučavanjem dostupnih baza (LIVE Mobile, VQEG HD i FERIT-RTRK UHD VFD baza podataka), ustanovljeno je kako baze ne sadrže spore video sekvence. Stoga je u sklopu ovog rada kreirana baza koja je sastavljena isključivo od sporo promjenjivih sekvenci, s vrlo malo pomaka. Baza se sastoji od 20 degradiranih video sekvenci, kreiranih iz 10 referentnih video sekvenci. 10 degradiranih sekvenci sadrži jedan interval smrzavanja, dok preostalih 10 degradiranih video sekvenci sadrži dva intervala smrzavanja.

Kako bi bila pogodna za testiranje, novostvorena SMVS FullHD baza sadrži različite vrijednosti i kombinaciju prostorno-vremenskih aktivnosti, no većinom su vrijednosti vremenskih aktivnosti manje zbog manje količine aktivnosti koje scena sadrži. Testiranje se provodi na HBFDA i RTFDA algoritmima. Dobiveni rezultati pokazuju kako oba algoritma imaju vrlo malu preciznost, odnosno da uz detekciju okvira koji predstavljaju stvarno smrzavanje, detektiraju i mnogo okvira koji nisu dio smrzavanja. Spori pokreti, promjena svjetline ili kontrasta, predstavljaju promjene koje ljudsko oko lako može uočiti, no algoritmi ih teško detektiraju kao takve te ih klasificira kao smrzavanje. Stoga za video sekvence novostvorene baze s malom vrijednošću vremenske aktivnosti, algoritmi detektiraju artefakt smrzavanja gotovo duž cijelog intervala trajanja video signala, jer ne mogu detektirati što je stvarno smrzavanje, a što vrlo spor pomak. Takve video sekvence, s vrlo malo promjena u vremenu, kod kojih je teško razaznati što je stvarno smrzavanje, a što pokret koji je teško uočljiv, mogu se koristiti pri unaprjeđenju algoritama za detekciju artefakata smrzavanja, jer kako je već navedeno, sustavi u današnje vrijeme ne toleriraju pogreške.

LITERATURA

[1] B. R. Ramancha, “Performance Analysis Of No-reference Video Quality Assessment Methods For Frame Freeze and Frame Drop Detection“, 2014.

[2] M. A. Usman, “PERFORMANCE EVALUATION OF VIDEO QUALITY ASSESSMENT METHODS BASED ON FRAME FREEZING,” 2014.

[3] M. A. Usman, M. R. Usman, and Soo Young Shin, “A no reference method for detection of dropped video frames in live video streaming,” in *2016 Eighth International Conference on Ubiquitous and Future Networks (ICUFN)*, Vienna, Austria, 2016, pp. 839–844.

[4] S. Winkler and P. Mohandas, “The Evolution of Video Quality Measurement: From PSNR to Hybrid Metrics,” *IEEE Trans. Broadcast.*, vol. 54, no. 3, pp. 660–668, 2008.

[5] D. Babić, D. Stefanović, M. Vranješ, and M. Herceg, “Real-time no-reference histogram-based freezing artifact detection algorithm for UHD videos,” *Multimed. Tools Appl.*, vol. 78, no. 13, pp. 17949–17971, 2019.

[6] R. Grbić, D. Stefanović, M. Vranješ, and M. Herceg, “Real-time video freezing detection for 4K UHD videos,” *J. Real-Time Image Process.*, vol. 17, no. 5, pp. 1211–1225, 2020.

[7] A. K. Moorthy, L. K. Choi, G. deVeciana, and A. C. Bovik, ‘Subjective Analysis of Video Quality on Mobile Devices,’ Sixth International Workshop on Video Processing and Quality Metrics for Consumer Electronics (VPQM) (invited article), Scottsdale, Arizona, Sjedinjenje Američke Države, 2012.

[8] A. K. Moorthy, L. K. Choi, A. C. Bovik, and G. de Veciana, “Video Quality Assessment on Mobile Devices: Subjective, Behavioral and Objective Studies,” *IEEE J. Sel. Top. Signal Process.*, vol. 6, no. 6, pp. 652–671, 2012.

[9] A. K. Moorthy, L. K. Choi, G. deVeciana, and A. C. Bovik, ‘Mobile Video Quality Assessment Database,’ IEEE ICC Workshop on Realizing Advanced Video Optimized Wireless Networks, Ottawa, Kanda, 2012.

[10] Webster, A., Speranza, F.: VQEG report on the validation of video quality models for high defnition video content. Technical report, Video Quality Experts Group (2010).

[11] “Free Stock Photos, Royalty Free Stock Images & Copyright Free Pictures · Pexels.” https://www.pexels.com/, pristup ostvaren 28.6.2022.

[12] “ffmpeg Documentation.” https://ffmpeg.org/ffmpeg.html, pristup ostvaren 11.6.2022.

[13] “FFmpeg Filters Documentation.” https://ffmpeg.org/ffmpeg-filters.html#freezedetect, pristup ostvaren 11.6.2022.

SAŽETAK

U ovom radu opisan je sadržaj i postupak kreiranja baze video sekvenci s prisutnim artefaktom smrzavanja. Artefakt se manifestira na način da se pri reprodukciji ponavlja posljednji ispravno preneseni okvir video signala. Detekcija artefakata vrši se specijaliziranim algoritmima, a u ovom radu proučavan je način rada, kao i uspješnost detekcije HBFDA i RTFDA algoritma nad do sada objavljenim bazama video sekvenci. Sve baze su proučene, detektirani su njihovi nedostaci, a izrada nove baze video sekvenci temeljena je na dobivenim rezultatima analize. Video sekvence od kojih je formirana nova, SMVS FullHD baza podataka, različitog su sadržaja, no sadrže malu količinu vremenskih promjena unutar cjelokupne video sekvence. Na kraju rada predstavljeni su rezultati izvršenja implementiranih algoritama nad generiranim sekvencama novostvorene baze.

Ključne riječi: artefakt smrzavanja slike, algoritam bez pristupa informaciji o referentnoj video sekvenci, baze podataka video sekvenci

EVALUATION OF THE SOLUTIONS FOR FREEZING ARTIFACT DETECTION IN THE VIDEO SIGNAL ON A NEWLY CREATED VIDEO SIGNAL BASE

ABSTRACT

This paper describes the content and procedure of creating a database of video sequences with the presence of a freezing artifact. The artifact manifests itself in the way that the last correctly transmitted frame of the video signal is repeated during playback. Artifacts are detected using specialized algorithms, and in this work, the method of detection was described, as well as the detection success of the HBFDA and RTFDA algorithms over the video sequence databases published so far. All databases were studied, their shortcomings were detected, and the creation of a new database of video sequences was based on the results of the analysis. The video sequences from which the new, SMVS FullHD database was formed, have different content, but contain a small amount of time changes within the entire video sequence. At the end of the paper, the results of the implementation of the given algorithms on the video sequences of the new database are presented.

Keywords: image freezing artifact, no-reference algorithm, video database

ŽIVOTOPIS

Ela Vrtar rođena je 17. siječnja 1999. godine u Našicama. Osnovnu školu J.J. Strossmayera od 1. do 4. razreda pohađala je u Beljevini, dok je preostale razrede osnovne škole završila u istoimenoj školi u Đurđenovcu. Nakon završene osnovne škole upisuje opću gimnaziju u Srednjoj školi Isidora Kršnjavoga u Našicama, koju završava s odličnim uspjehom. 2017. godine upisuje sveučilišni preddiplomski studij elektrotehnike na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija u Osijeku. U rujnu 2020. godine uspješno obrađuje završni rad na temu "Aktivni pojasno propusni filtri u izvedbi s operacijskim pojačalom". Iste godine upisuje diplomski studij, izborni blok komunikacije i informatika, modul DKB- mrežne tehnologije.

Potpis:

_____