VSI metrika za objektivnu ocjenu kvalitete slike

Čanađija, Marko

Undergraduate thesis / Završni 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:200:682905

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

Download date / Datum preuzimanja: **2025-03-25**

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

VSI METRIKA ZA OBJEKTIVNU OCJENU KVALITETE SLIKE

Završni rad

Marko Čanađija

Osijek, 2016.

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Obrazac Z1P - Obrazac za ocjenu završnog rada na preddiplomskom sveučilišnom studiju

Osijek,

Odboru za završne i diplomske ispite

Prijedlog ocjene završnog rada

Ime i prezime studenta:	Marko Čanađija
Studij, smjer:	Preddiplomski sveučilišni studij Elektrotehnika
Mat. br. studenta, godina upisa:	3724, 27.08.2013.
OIB studenta:	47197537442
Mentor:	Doc.dr.sc. Mario Vranješ
Sumentor:	
Naslov završnog rada:	VSI metrika za objektivnu ocjenu kvalitete slike
Znanstvena grana rada:	**Telekomunikacije i informatika (zn. polje elektrotehnika)**
Predložena ocjena završnog rada:	
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: Postignuti rezultati u odnosu na složenost zadatka: Jasnoća pismenog izražavanja: Razina samostalnosti:
Datum prijedloga ocjene mentora:	
Datum potvrde ocjene Odbora:	

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

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

IZJAVA O ORIGINALNOSTI RADA

Osijek, 07.09.2016.

Ime i prezime studenta:	Marko Čanađija
Studij:	Preddiplomski sveučilišni studij Elektrotehnika
Mat. br. studenta, godina upisa:	3724, 27.08.2013.
Ephorus podudaranje [%]:	

Ovom izjavom izjavljujem da je rad pod nazivom**: VSI metrika za objektivnu ocjenu kvalitete slike**

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

i sumentora

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

Potpis studenta:

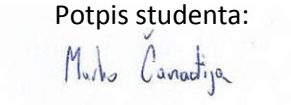

SADRŽAJ

1.UVOD 1

1.1. Zadatak završnog rada 1

2. OCJENA KVALITETE SLIKE 2

2.1. Subjektivne metode 2

2.1.1. Subjektivna metoda ocjenjivanja s jednostrukim podražajem bez referentne slike 2

2.1.2. Subjektivna metoda ocjenjivanja s dvostrukim podražajem i s referentnom slikom 2

2.1.3. Subjektivna metoda rangiranja para slika 3

2.1.4. Subjektivna metoda ocjenjivanja para slika 3

2.1.5. Ukupni rezultat subjektivnih metoda 3

2.2. Objektivne metode 4

2.2.1. Podjela objektivnih metoda s obzirom na potrebu za referentnom slikom 4

2.2.1.1. NR-IQA metode 4

2.2.1.2. RR-IQA metode 5

2.2.1.3. FR-IQA metode 5

2.2.2. Podjela objektivnih metoda s obzirom na način analize dekodirane slike 7

2.2.2.1 Podatkovne metrike 7

2.2.2.2. Slikovne metrike 7

2.2.2.3. Metrike zasnovane na paketima i prijenosu bita 7

3. VSI METRIKA ZA OCJENU KVALITETE SLIKE 9

3.1. Računalni modeli vizualne upadljivosti 9

3.2. Postojeća istraživanja vizualne upadljivosti za primjenu kod ocjene kvalitete slike 10

3.3 Opis algoritma VSI metrike 11

4. OCJENA KVALITETE SLIKE RAZLIČITIM METRIKAMA 18

4.1. Baza testnih slika 18

4.2. Opis ocjene kvalitete VSI metrikom 22

4.3. Diskusija o rezultatima 27

5. ZAKLJUČAK 30

LITERATURA 31

SAŽETAK 35

ŽIVOTOPIS 36

1.UVOD

Posljednjih godina sve je veća uporaba aplikacija kojima su glavna obilježje slike, te je potrebno da kvaliteta slike bude u svakom trenutku zadovoljavajuća. Sve je veći interes za istraživanja i razvoj programa u kojima se istražuje što ljudima, kao krajnjim korisnima, privlači pažnju, kao i za programima s kojima se kvaliteta slike provjerava u svakom trenutku. Za takva istraživanja ljudi su najbolji izvor za procjenu kvalitete, jer su oni najčešći korisnici. Međutim, istraživanje u kojemu će ljudi ocjenjivati kvalitetu je dugotrajan i skup proces, te se ne može primijeniti u aplikacijama gdje je potrebna procjena kvalitete u stvarnom vremenu. Zato znanstvenici rade na tome da konstruiraju računalne modele, kojima će se moći procijeniti kvaliteta slika bez potrebe za prisustvom ljudi, te koji će se moći koristiti u aplikacijama gdje je potrebna procjena kvalitete u stvarnom vremenu. Takve metode ocjenjuju slike objektivno, na temelju postavljenih parametara, dok kod ljudi ocjenjivanje kvalitete ovisi o subjektivnom mišljenju i raspoloženju.

U ovom radu će se u drugom poglavlju, najprije objasniti subjektivna metoda procjene kvalitete slike i neki od načina na koji se ocjenjuje. Zatim će se objasniti objektivne metode, i dati dvije njihove podjele. U trećem poglavlju je detaljno objašnjena VSI (engl. *Visual Sailency Index*), metrika kao i računalne metode koje su dovele do razvoja metrike, istraživanja koja se postoje u razvoju i poboljšanju metode, te opis VSI algoritma i načina na koji on radi. Četvrto poglavlje sadrži rezultate eksperimenta usporedbe ocjena subjektivne metode, dviju postojećih objektivnih metode i VSI metrike i opis eksperimenta korak po korak, te diskusiju o rezultatima. Peto poglavlje sadrži zaključak ovoga rada.

1.1. Zadatak završnog rada

Zadatak ovog završnog rada je opisati objektivno i subjektivno ocjenjivanje kvalitete slike, detaljno opisati VSI metriku za ocjenu kvalitete slike. Eksperimentalno ocijeniti objektivnu kvalitetu baze slika različitim metrikama, zatim raspravljati o razlikama među ocjenama različitih metrika i subjektivnim ocjenama iste baze slika.

2. OCJENA KVALITETE SLIKE

2.1. SUBJEKTIVNE METODE

Ljudi su najčešći korisnici većine multimedijskih aplikacija te su oni ujedno i najpouzdaniji i najbolji za subjektivnu ocjenu kvalitete slike. Prema tome, sama subjektivna metoda ocjene kvalitete slike bazira se na tome da se grupi ljudi podjele slike iz neke baze podataka i oni na temelju svojih mišljenja i dojmova ocjenjuju svaku sliku zasebno. Na temelju tih ocjena, bilo koja druga metoda (računalna) ne bi smjela dati preveliko odstupanje od rezultata subjektivne metode jer su ljudski ispitanici najpouzdaniji. Da bi ispitivanje bilo mjerodavno i da bi rezultati bili pouzdani za kasnija istraživanja, moraju se ispuniti neki od internacionalnih standarda, kao što su udaljenost promatranja, uvjeti osvjetljenja te zaslon uređaja na kojem se vrši prikaz tih slika. Uz te standarde ima još nekoliko faktora koji znatno utječu na rezultate ispitivanja, koji se ne mogu mijenjati ili podešavati, kao što su promatračke sposobnosti i raspoloženje ispitanika. Zbog toga je ispitivanje subjektivnom metodom ocjene kvalitete slike kompliciran, skup i dugotrajan proces, koji je još i samim time nepraktičan za aplikacije u stvarnom vremenu. Stoga je neophodno pronaći matematički algoritam, odnosno metodu, kojom bi bilo moguće predvidjeti prosječnu ocjenu kvalitete ljudskih promatrača. U nastavku će biti opisane neke od standardnih subjektivnih metoda za ocjenu kvalitete slike (engl. *Image quality assessment - IQA*).

2.1.1. Subjektivna metoda ocjenjivanja s jednostrukim podražajem bez referentne slike

U metodi subjektivnog ocjenjivanja s jednostrukim podražajem bez referentne slike (engl. *single stimulus categorical reating)*, slika na kojoj se vrši ispitivanje prikazana je određeno vrijeme na zaslonu ekrana, nakon toga slika nestane s ekrana. Na promatraču je ocjeniti kvalitetu slike prema ljestvici koja je podijeljena u pet kategorija: izvrsno, dobro, u redu, siromašno ili loše. Slike koje se koriste u testiranju nasumično se mijenjaju, da bi se izbjegla kvantizacija artefakata. Neke metode koriste radije kontinuiranu nego kategoričnu skalu [1].

2.1.2. Subjektivna metoda ocjenjivanja s dvostrukim podražajem i s referentnom slikom

Subjektivna metoda ocjenjivanja s dvostrukim podražajem i s referentnom slikom (engl. *Double stimulus categorical reating*) slična je subjektivnoj metodi ocjenjivanja s jednostrukim podražajem bez referentne slike. U obje metode se slika na kojoj se vrši testiranje prikazuje određeno vrijeme, i nakon toga slika nestane s ekrana, te promatrač mora ocijeniti sliku, kako je

već unaprijed objašnjeno. U ovoj metodi uz testnu sliku još se prikazuje i referentna slika, a na promatraču je ocjeniti testnu sliku.

2.1.3. Subjektivna metoda rangiranja para slika

Kod subjektivne metode rangiranja para slika (engl. *Ordering by force-choice pair-wise comparison* **),** promatraču su u isto vrijeme prikazane dvije slike istog sadržaja. Pri korištenju ove metode nema vremenskog ograničenja i promatrač treba dobro promotriti slike. Nakon vremena koje mu je dovoljno kako bi odlučio, mora izabrati koja slika ima bolju kvalitetu, bez obzira ako su te dvije slike identične. Nedostatak ovog pristupa je potreba za veći broj ispitivanja, da bi se usporedio pojedini par uvjeta [2]. U [3,4], su objašnjene dvije metode kod kojih je smanjen broj ispitivanja.

2.1.4. Subjektivna metoda ocjenjivanja para slika

U metodi subjektivnog rangiranja para slika promatraču je ponuđeno da izabere između dviju slika istog sadržaja, te odluči koja je slika bolje kvalitete, bez obzira ima li uopće razlike. U subjektivnoj metodi ocjenjivanja para slika (engl. *pair-wise similarity judgments*) na promatraču je još i da iskaže za koliko je bolja kvaliteta odabrane slike. Razliku između tih kvaliteta na slikama iskazali bismo na kontinuiranoj skali. Kako bi se negdje mogla koristiti gruba ocjenjivanja (odlično, vrlo dobro, dobro itd.), ti rezultati, zapravo, nisu pouzdani. Jedan od razloga je što bi promatrači mogli koristiti drugačije pristup za ocjenjivanje slika različitih sadržaja, te bi moglo doći i do različitih percepcija izobličenja na slikama i njihovim sadržajima [5].

2.1.5. Ukupni rezultat subjektivnih metoda

Kao ukupni rezultat subjektivnih metoda najčešće se računa MOS (engl. *Mean opinion score)*, u kojemu se računa srednja vrijednost rezultata svih gledatelja za neku sliku. Postoji još i DMOS (engl. *Difference mean opinion score*) kojim se umjesto ocjene slika, dobiva razlika između ocjene referentne i testne slike. DMOS se računa pomoću sljedeće formule:

$$d_{i,j} = r_{i,ref}(j) \quad r_{i,j} \tag{2-1}$$

gdje je $r_{i,j}$ ocjena za *i*-tog gledatelja i *j*-tu sliku, a $r_{i,ref}(j)$ označuje ocjenu *i*-tog gledatelja za referentnu sliku odgovarajuće *j*-te testne slike. Koristi se još i Z-score, a detaljnije je opisan u [6].

2.2. OBJEKTIVNE METODE

Kako su subjektivne metode najbolji način za IQA, ali su dugotrajne, skupe i komplicirane te se još ne mogu koristiti za aplikacije u stvarnom vremenu, potrebno je smisliti matematički model kojim bi se objektivno ocjenjivale slike bez potrebe za ljudskim promatračem. Glavni cilj objektivnih metoda je da automatski i precizno predvidi ocjene za kvalitetu slike. Najbolje rezultate objektivnog ocjenjivanja ostvarili bi kada bi se moglo u potpunosti imitirati ocjenjivanje prosječnog ljudskog promatrača. Objektivne metode za IQA imaju široku primjenu u aplikacijama [7], a neke od njih su:

- sustavi za kontrolu kao i sustavi za prikupljanje koriste objektivne metode za IQA za praćenje i automatsku prilagodbu da bi održali najbolju kvalitetu podatka za pojedinu sliku
- objektivne IQA metode mogu se koristiti kada nam je ponuđen veći broj algoritama, te je njihov zadatak odabrati algoritam koji će dati najtočniju kvalitetu slike
- za optimizaciju algoritama za obradu slike pri prijenosu i prilagodbu sustava za prijenos, u mrežama za vizualne komunikacije objektivni IQA zadužen je za optimizaciju filtriranja prije razbijanje algoritma u koderu i optimiziranje filtriranja poslije rekonstrukcije algoritma u dekoderu.

2.2.1. Podjela objektivnih metoda s obzirom na potrebu za referentnom slikom

Obzirom na dostupnost slika odlične kvalitete i bez deformacija, objektivne IQA metode mogu se podijeliti u tri grupe: prva grupa je FR-IQA (engl. *Full-reference image quality assessment)* gdje je referentna slika cijela na raspolaganju, kao i informacije o njoj; druga grupa je RR-IQA (engl. *Reduced-reference image quality assessment)* gdje su dostupni samo djelomični podaci o referentnoj slici; treća grupa je NR-IQA (engl. *no-reference image quality assessment)* u kojoj nema referentne slike i nikakvih podataka o njoj.

2.2.1.1. NR-IQA metode

U aplikacijama koje se većinom koriste u stvarnom svijetu, kao što su slike u komunikacijskim sustavima, referentna slika nije dostupna te se procjena kvalitete temelji na probnoj slici. Kako kod NR-IQA metode nemamo nikakve podatke o referentnoj slici, cijeli zadatak usporedbe je zahtjevniji nego kod FR-IQA ili RR-IQA. Ljudi su bića koja mogu efikasno procijeniti kvalitetu probne slike, bez da koriste referentnu sliku. Razlog tome je što ljudski mozak čuva informacije o tome kako bi ili kako ne bi slika dobro izgledala u stvarnom svijetu. Neke od NR-IQA metoda mogu se pronaći u [8-10].

2.2.1.2. RR-IQA metode

Kod ovih metoda referentna slika nije u potpunosti poznata nego su poznate samo neke značajke o njoj, te se referentne i testne slike uspoređuju na temelju tih značajki. Te značajke su upotrjebljene od strane metode za procjenu kvalitete, kao dodatna informacija za izračun kvalitete testne slike. RR-IQA može biti korištena u različitim aplikacijama. Jedna od primjena je kod praćenja vizualne kvalitete slika i videa emitiranih preko mreža za vizualnu komunikaciju u stvarnom vremenu. Vrlo važan parametar kod RR-IQA sustava je brzina prijenosa podataka korištenih za šifriranje dodatne informacije. Ako je dostupna veća brzina prijenosa podataka, poznato je više informacija o referentnoj slici, što omogućava precizniju procjenu kvalitete. Tada se može RR-IQA smatrati kao FR-IQA. S druge strane, ako je brzina prijenosa podataka mala, poznat je mali broj informacija o referentnoj slici, čime su rezultati procjene kvalitete manje precizni. Kada je brzina prijenosa informacija jednaka nuli, RR-IQA možemo smatrati NR-IQA. U stvarnom svijetu, kod RR-IQA sustava, maksimalna dozvoljena brzina prijenosa informacija obično je mala, ta ograničene vrijednosti ograničavaju izbor svojstava u procesima kod RR-IQA sustava. Određena svojstva morala bi zadovoljavati neke od sljedećih kriterija:

- pružiti učinkovit sadržaj referentne slike
- biti osjetljive na razne vrste izobličenja
- sadržavati dobru opažajnu značajnost

RR-IQA može se raščlaniti na metode temeljene na modelu izvora slike, metode koje su temeljne na zabilježenim izobličenjima slika, te metode temeljene na modelu ljudskog vizualnog sustava. Više o tim podjelama može se pronaći u [11].

2.2.1.3. FR-IQA metode

Kod ovih metoda potpuno je poznata i dostupna referentna slika za proces predviđanja kvalitete slike. Objektivno procjenjivanje kvalitete slike ovim metodama vrši se tako da se uspoređuje referentna s testnom deformiranom slikom. Postoji mnoštvo različitih objektnih postupaka koji će kasnije bili objašnjeni, te se često navode u literaturi. FR metode na temelju razlika između originalne i izobličene slike mjere kvalitetu slika. Od mnogo poznatih metoda koje pripadaju FR postupcima, PSNR (*engl. Peak Signal to Noise Ratio)* je metoda koja je jedna od najpopularnijih i najjednostavnijih za korištenje. PSNR metodom dobivaju se ocjene kvalitete, odnosno stupanj izobličenja između testne slike koja se promatra, radi usporedbe s referentnom slikom. Metoda se predstavlja kao logaritamski omjer maksimalne snage signala

i snage šuma koja je ekvivalentna iznosu MSE *(*engl. *Mean Square Error)* odnosno srednje kvadratne pogreške referentne i testne izobličene slike:

$$MSE = \frac{1}{WH}\sum_{j=1}^{H}\sum_{i=1}^{W}(I_{ref}(i,j) \quad I_{tst}(i,j))^2 \tag{2-2}$$

I_{ref} i I_{tst} odnose se na referentnu i na testnu sliku, a W i H predstavljaju visinu i širinu slike u broju elemenata slike. Rezultat PSNR metode izražava se u decibelima, te kako je veća vrijednost PSNR-a, kvaliteta slike je bolja. PSNR se računa kao [6]:

$$PSNR = 10\log(\frac{D^2}{MSE}) \tag{2-3}$$

D predstavlja maksimalnu vrijednost intenziteta elemenata slike (kao primjer za sliku od 8 bitova po elementu slike, D iznosi 255). Drugi često korišteni objektivni postupak je SSIM (engl. *Structural Similarity Index*) kojim se pokušavaju iskoristiti svojstva ljudskog vizualnog sustava koji je osjetljiv na razne deformacije, te razlike u kontrastu i svjetlini koje nastaju na testnoj slici, pomoću kojih se može odrediti kvaliteta. SSIM se računa kao [6]:

$$SSIM(I_{ref,}I_{tst}) = [l(I_{ref,}I_{tst})]^{\alpha}[c(I_{ref,}I_{tst})]^{\beta}[s(I_{ref,}I_{tst})]^{\gamma} \tag{2-4}$$

l je funkcija za usporedbu osvjetljenja*, c* je funkcija za usporedbu kontrasta, a funkcija za usporedbu strukture je s, te su α, β i γ pozitivne konstante odabrane za pokazivanje relativne važnosti svake komponente. Rezultati su dani između 0 i 1, gdje 1 pokazuje da su slike potpuno identične, a 0 da slike nemaju nikakve sličnosti. Više o SSIM postupku može se naći u [6]. Sljedeći često korišteni FR postupak je MS-SIM [12] (engl. *Multi-scale SSIM)* koji se temelji na SSIM [13], ali je napredniji, pa se kontrast, svjetlina i struktura računaju na različitim frekvencijskim ljestvicama. Rezultati ove metode se mogu podešavati tako što se može mijenjati udaljenost promatrača u odnosu na testnu sliku. Zato je ova metoda prilično dobra. VIF (engl. *Visual Information Fidelity*) [14] je postupak kojim se određuje istinitost vizualne informacije. Postupak rangira odnos informacija koje su zajedničke referentnoj i testnoj slici, u odnosu na informaciju u referentnoj slici. Kod ove metode se koristi NSS (engl. *Natural Scene Statistic)* model prirodne scene, zajedno (engl. *Human Visual System - HSV*) s modelom ljudskog vizualnog sustava. Metode koje još postoje su MAD (engl. *Most apparent distortion*)

[15], FSIM (engl. *Feature similarity index*) [16] … Važno je napomenuti da su sve metrike dizajnirane za slike u skali sivog.

2.2.2. Podjela objektivnih metoda s obzirom na način analize dekodirane slike

2.2.2.1 Podatkovne metrike

Podatkovne metrike *(*engl. *Data metrics)* mjere točnost signala bez modeliranja bilo kakvih svojstava HVS-a. Popularne podatkovne metrike su MSE, kao i PSNR. Metode nisu komplicirane i lako ih je shvatiti i provesti. Zato se često koriste u procjeni kvalitete slike. Ove metode ne mogu u potpunosti dati objektivnu ocjenjenu kvalitete koja odgovara ocjeni ljudskih promatrača za širok raspon parametara kodiranja i prijenosa. To se događa zato što uspoređuju testne i referentne podatke, bez da se zna šta oni zapravo predstavljaju. Ne uzimaju u obzir karakteristike HVS-a, koje pokazuju da HVS nema istu osjetljivost na različita vrste izobličenja i različita svojstva izobličenja. Povrh toga, vrlo je važno da se zna u kojem dijelu slike se izobličenje pojavi, a MSE ili PSNR ne uzimaju to u obzir. Podatkovne metrike se koriste za prijenos slika preko Interneta, te često koriste BER (engl. *Bit Error Rate*) i PLR (engl. *Packet Loss Rate*). Te metode učinkovito mjere postotak pogrešno poslanih bitova i izgubljenih paketa, ali ne mjere precizno i točno kvalitetu slike.

2.2.2.2. Slikovne metrike

Slikovne metrike *(*engl. *Picture Metrics)* koriste se kako bi se izbjegli nedostaci koji se pojavljuju kod običnih podatkovnih metrika. Mnoge objektivne slikovne metrike pokušavaju predvidjeti i spoznati kvalitetu slike, uzimajući u obzir sadržaj i vrstu izobličenja. Analizira se vizualna informacija sadržana u slikovnom podatku. Ovisno o pristupu korištenom u osmišljavanju metrike, slikovne metrike se mogu podijeliti u dvije grupe: vizualno modelirani pristup i inženjerski pristup. Slikovne metrike mogu se još klasificirati kao perceptivno orijentirane i perceptivno orijentirane s prirodnim vizualnim karakteristikama. Perceptivno orijentirane metrike koriste vizualno modelirani pristup, dok perceptivno orijentirane s prirodnim vizualnim karakteristikama koriste inženjerski pristup, koji se prvenstveno bazira na izvlačenju i analiziranju pojedinih značajki predmeta za upotrebu iz slika, umjesto korištenja osnovnih vizualnih modela. Pristup modeliranja vida, kao i inženjerski pristup detaljnije su objašnjeni u [17].

2.2.2.3. Metrike zasnovane na paketima i prijenosu bita

Metrike zasnovane na paketima i prijenosu bita (engl. *Packet and Bitstream based metrics*) našle su svoju primjenu. Kako se posljednjih godina povećao broja usluga koji posjeduju opciju slanje slika preko IP mreže, postalo je potrebno da se razvije IQA metrika koja će uzeti u obzir

gubitke u mreži, kao i kvalitetu slika. Kada se neki od paketa izgubi u prijenosu kroz mrežu, neophodno je otkriti koliko je informacija izgubljeno u njima. Ova metoda izvlači nekoliko parametara iz prijenosnog toka bez ili s nešto malo dekodiranja. Metrika je detaljnije objašnjena u [17] .

3. VSI METRIKA ZA OCJENU KVALITETE SLIKE

Posljednjih godina veliku pažnju je privukla ideja kako osmisliti učinkoviti računalni model za vizualnu upadljivost, odnosno kraće VS *(*engl. *Visual Sailency)*. Slika je računalna VS mapa koja s prikladnim VS modelom može prikazati kako će lokalna „upadljivost" utjecati na HVS. VS i IQA su istinski povezani zato što obje metode ovise o tome kako HVS percipira sliku te kako granična izobličenja mogu biti snažan faktor kod vizualnog zapažanja. Tako su u posljednje vrijeme znanstvenici pokušavali spojiti VS informacije s IQA modelom kako bi povećali njezine performanse. Istraživanja su pokazala da VS informacije na odgovarajući način mogu doprinijeti performansama IQA metrike, štoviše primijenjeni, digitalizirani IQA model zasnovan na VS ostvaruje bolje predviđanje karakteristika od ostalih najsuvremenijih metoda kao što su IW-SSIM [18], $FSIM_C$[19] i GSM [20]. Analiziranjem odnosa između promjena slika iz VS mape i podjele njihovih procjena kvaliteta, može se predstaviti vrlo jednostavan i vrlo učinkovit indeks zasnovan na vizualnoj upadljivosti *(*engl. *Visual Sailency Indeks)* sa zadatkom IQA. VS mape ne trebaju biti korištene samo u funkciji težinskog faktora u fazi združivanja rezultata nego i za korištenje kao mape stavki za obilježavanje kvalitete kod slika u lokalnom području. Glavni razlog je to što sitna izobličenja u kvaliteti mogu dovesti do znatnih promjena slika u mapama vizualne upadljivosti. Kod VSI metrike, VS mapa slika ima dvojaku ulogu: (1) svojstva mape opisuju lokalnu kvalitetu slika, (2) kao funkcija težinskog faktora koja pokazuje važnost lokalnog područja u HVS kada se zahtjeva konačna ocjena kvalitete. VSI je detaljno testiran na četiri baze podataka [21]. Rezultati pokazuju da je VSI u rangu s drugim najsuvremenijim IQA metrikama. Povrh toga, njezina računalna složenost je vrlo mala. Detaljnije je objašnjena u [21].

3.1. Računalni modeli vizualne upadljivosti

Kod ljudi se postepeno razvijala zavidna sposobnost da automatski bolje primijete istaknuta područja kod nekih vizualnih prizora. Pri konstrukciji modela koji oponašaju ljudsko vizualno zapažanje, vršena su istraživanja iz područja neurobiologije, psihologije i računalnog vida dugi niz godina, kako bi se razvili neki modeli. Iako postoje pristupi slikama odozdo prema gore *(*engl. *Bottom-up)* i odozgo prema dolje *(*engl. *Top-down)*, većina računalnih modela koriste pristup odozdo prema gore, zato što je taj pristup detaljnije proučen. U pristupu odozdo prema gore kod VS modela pretpostavljeno je da vizualno opažanje koristi niže razine vizualnih stimulacija kod prizora, kao što su intenziteti, boja, orijentacija…

Prvi utjecajni i najbolji VS model predstavili su Itti i drugi u [22] za mirne slike. Model se bazirao na VS računalnoj arhitekturi predstavljenoj od Koch i Ullman [23]. Itti-jev doprinos

bazirao se na dva aspekta. Prvi aspekt predstavlja slike piramida za ekstrakciju značajki koje čine računalni VS učinkovitim, a drugi aspekt inspiriran je biološkom operacijom „razlika sredina-okolina“, za računalna svojstva ovisno o upadljivosti mapa kroz skalu. Kasnijim radom Itti i Baldi su predstavili Bayesian-ov model, kojemu je bio cilj predvidjeti pokrete očiju [24]. Predstavljeni su još GBVS (engl. *Graph-based visual sailency*) metoda, metoda bazirana na Furierovoj transformaciji za ekstrakciju SR (*engl. Spectral residual*), algoritam upadljivosti zasnovan na IS (*engl. Image signature*), model pažnje zasnovan na maksimizaciji informacija AIM (engl. *Attention based on information maximization*), te učinkoviti algoritam upadljivosti zvan SDSP (engl. *Saliency Detection by combining Simple Priors*) koji je koristio predznanje triju poznatih aspekata: boje, frekvencije i lokacije. Detaljnije objašnjene metode, kao i neke druge, opisane su i objašnjene u [21].

3.2. Postojeća istraživanja vizualne upadljivosti za primjenu kod ocjene kvalitete slike

Spoznaja da postoji bliska veza između VS i percepcije kvalitete, dovela je do razvoja nekolicine pristupa kojima se pokušalo integrirati VS u IQA metriku kako bi povećalo svojstvo predviđanja. U [25] Vu je smislio dva eksperimenta za ispitivanje određenog vizualnog uzorka kada se ocjenjuje kvaliteta slike. Rezultati su otkrili područje na koje su ljudi fiksirani pri ocjenjivanju kvalitete slike, te ono može biti različito od onih koji su napravljeni bez uvjeta. Pet često korištenih metrika proširene su koristeći dvije vrste podataka usmjerenosti, prvi slučaj je bez uvjeta, dok je kod drugog traženo od promatrača da ocjene kvalitetu slike. Rezultati su pokazali da se većina metrika mogu unaprijediti korištenjem određenih podataka, te je veće poboljšanje pronađeno u slučaju bez uvjeta. U [26] Larson je otkrio da se slične metrike (kao što su SSIM, PSNR, VIF…) mogu unaprijediti korištenjem prostorno promjenjivog težinskog udruživanja. U [27] je pokazao da se trenutna metrika kvalitete može poboljšati tako da se slika segmentira u ROI (engl. *Region of interest*) i pozadinske dijelove. Takvom metodom metrika se računa neovisno na ROI i pozadinskim regijama i onda se koristi funkcija udruživanja za dobivanje konačne ocjene kvalitete. Ova metoda se ne može koristiti za aplikacije gdje je potrebna potpuna automatska IQA metrika. Bolje je onda koristiti praćenje oka ili subjektivne ROI podatke. Znanstvenici su pokušali povezati izračunate VS informacije, dobivene korištenjem računalnog VS modela za IQA modele.

Prvo, ova ispitivanja zasnovana su na pretpostavci da su izobličenja u područjima koja više privlače pažnju promatrača, nego neka druga područja, te pokušavaju izmjeriti izobličenja mapom upadljivosti. Drugo, ova metoda ne služi za stvaranje novog IQA indeksa, nego da prikaže da se VS težinsko udruživanje može izvesti bolje nego jednostavne „prosječne“ sheme. Prema

tome, za računalnu mapu kvalitete, autori su prilagodili neke postojeće metode, kao što su PSNR, SSIM i VIF bez razmatranja hoće li biti učinkovitije za procjenu lokalne kvalitete slike. Treće, ima nedovoljno važnih proračuna da se može potvrditi učinkovitost predstavljenog IQA indeksa. Inače se istraživanja provode samo na određenim bazama podataka i samo s klasičnim IQA indeksima (kao što su SSIM, PSNR, VIF) koji su korišteni za usporedbu. S nekim suvremenijim, kasnije razvijenim IQA metrikama s odličnim karakteristikama, kao što su IW-SSIM [18], FSIM/FSIM$_C$[19] i GSM [20], usporedba nije izvršena.

3.3 Opis algoritma VSI metrike

U [19] Zhang je pokazao da znatno smanjenje kvalitete slike može dovesti do znatnih promjena u svojstvima slika lošije kvalitete. Budući da se pristup odozdo prema gore VS modela u osnovi bazira na svojstvima slika lošije kvalitete, vrijednosti VS zapravo variraju s promjenama kvalitete slike. Zašto se onda VS ne bi koristila kao element za računanje lokalne sličnosti između referentne slike i slike s nekakvom deformacijom? Time je došlo do pretpostavke da bi takve deformacije mogle dovesti do promjena u kvaliteti slika VS mape i intenzitet deformacije mjerljivih promjena dobro korelira promjenama sa stupnjem deformacije kvalitete. Da bi se ta tvrdnja potvrdila, obavljena je statistička analiza na slikama iz VS mape u TID2013 [28], najvećoj bazi podataka dostupnoj za IQA istraživanja. U TID2013 ima 25 referentnih slika, s 24 vrste deformacije i 5 stupnjeva deformacije. Prema tome, za jednu vrstu deformacije na određenom stupnju deformacije ima 25 uzoraka. Za izvođenje takve analize prvo se računa VS mapa za sve slike korištenjem GBVS modela [29] i zatim za svaku referentnu deformaciju para slika računa MSE između njihovih VS mapa. Nakon toga, pridjeljena je prosječne vrijednosti MSE istoj vrsti deformacije i istom stupnju deformacije. Rezultati su prikazani u tablici 3.1. te za svaku vrstu i stupanj deformacije u zagradama se nalaze prosječne subjektne ocjene. U TID2013 veća subjektivna ocjena označuje bolju kvalitetu slike. Prema rezultatima u tablici 3.1. dolazi se do sljedećih zaključaka: prvo, za približno sve vrste deformacija, manja prosječna subjektivna ocjena odgovara za lošije prosječne VS promjene izmjerene korištenjem MSE; drugo, čak i za većinu slučajeva u kojima je prisutno više različitih tipova deformacije, promjene u VS također mogu biti dobar pokazatelj opažene kvalitete slike.

Tablica 3.1 *Prosječna vrijednost MSE od VS i prosječna subjektivna ocjena za različite stupnjeve deformacije, [21]*

Dis. Type	Level 1	Level 2	Level 3	Level 4	Level 5
AGN	2.68 (5.67)	4.10 (5.23)	7.26 (4.85)	16.71 (4.25)	33.92 (3.77)
ANC	0.55 (5.93)	1.17 (5.85)	2.68 (5.53)	5.47 (5.06)	9.36 (4.48)
SCN	15.41 (4.76)	25.54 (4.24)	53.11 (3.70)	111.87 (3.20)	244.19 (2.69)
MN	1.04 (5.92)	2.15 (5.79)	5.12 (5.50)	12.09 (5.08)	32.30 (4.47)
HFN	0.58 (5.89)	1.18 (5.64)	3.57 (5.11)	11.12 (4.15)	39.36 (3.22)
IN	2.02 (4.71)	5.38 (4.36)	10.18 (3.98)	19.34 (3.64)	44.25 (3.20)
QN	10.21 (5.25)	25.17 (4.68)	49.95 (4.11)	107.71 (3.46)	311.32 (2.83)
GB	0.16 (5.65)	0.41 (5.03)	1.20 (4.15)	5.54 (3.31)	40.94 (2.45)
DEN	4.17 (6.06)	9.60 (5.75)	20.72 (4.82)	77.02 (3.44)	289.00 (2.02)
JPEG	0.97 (5.94)	2.73 (5.70)	10.71 (4.91)	68.89 (3.31)	205.86 (2.07)
JP2K	1.64 (5.65)	10.70 (5.02)	67.21 (3.91)	323.61 (2.79)	1350.75 (1.28)
JGTE	0.86 (5.74)	1.90 (5.40)	35.00 (4.61)	133.98 (3.87)	408.88 (2.97)
J2TE	15.27 (4.88)	43.04 (4.18)	48.60 (3.62)	200.03 (2.96)	269.04 (2.59)
NEPN	26.88 (5.72)	38.81 (5.89)	131.92 (5.33)	201.36 (4.71)	361.42 (3.85)
Block	604.50 (3.28)	466.45 (3.34)	459.34 (3.48)	385.14 (3.73)	307.11 (4.06)
MS	0.20 (6.07)	2.78 (6.06)	2.86 (5.63)	26.60 (5.34)	26.95 (4.65)
CTC	0.13 (5.62)	19.79 (6.48)	0.13 (4.48)	83.29 (6.29)	0.19 (3.45)
CCS	0.16 (5.06)	0.11 (4.66)	0.13 (4.23)	0.19 (3.92)	0.30 (3.69)
MGN	3.12 (5.52)	5.47 (5.13)	10.53 (4.69)	24.34 (4.13)	50.43 (3.68)
CN	1.21 (5.88)	3.68 (5.55)	13.93 (5.01)	66.72 (4.17)	200.58 (3.31)
LCNI	6.41 (5.51)	16.55 (5.00)	32.59 (4.32)	91.33 (3.53)	255.46 (2.49)
ICQD	2.86 (5.69)	7.87 (5.26)	36.06 (4.58)	89.54 (3.79)	350.14 (2.91)
CHA	0.71 (6.11)	3.53 (5.87)	28.09 (5.18)	104.38 (4.40)	436.12 (3.00)
SSR	2.67 (5.77)	9.63 (5.10)	68.65 (3.99)	498.20 (2.61)	1487.23 (0.95)

Odnos između količine deformacije i VS promjena mogu se prikazati korištenjem primjera sa sl. 3.1, koji su korišteni u TID2013. Sl. 3.1(a) je referentna slika, a sl. 3.1(c) i sl. 3.1(e) su slike s dvije vrste deformacije, a njihove subjektivne ocjene su 5.05 i 2.40 za svaku posebno. Sl. 3.1(b), sl. 3.1(d) i sl. 3.1(f) su VS mape od sl. 3.1(a), sl. 3.1(c) i sl. 3.1(e) zasebno. MSE između sl. 3.1(d) i sl. 3.1(b) je 4.49, dok MSE između sl. 3.1(f) i sl. 3.1(b) iznosi 198.36. Sl. 3.1(e) ima lošiju kvalitetu od sl. 3.1(c) kako je očekivano, njezine VS mapa, sl. 3.1(f), je promijenjena više nego kod sl. 3.1(c), (VS mapa sl. 3.1(d)) kada se usporedi s referentnom VS mapom sl. 3.1(b).

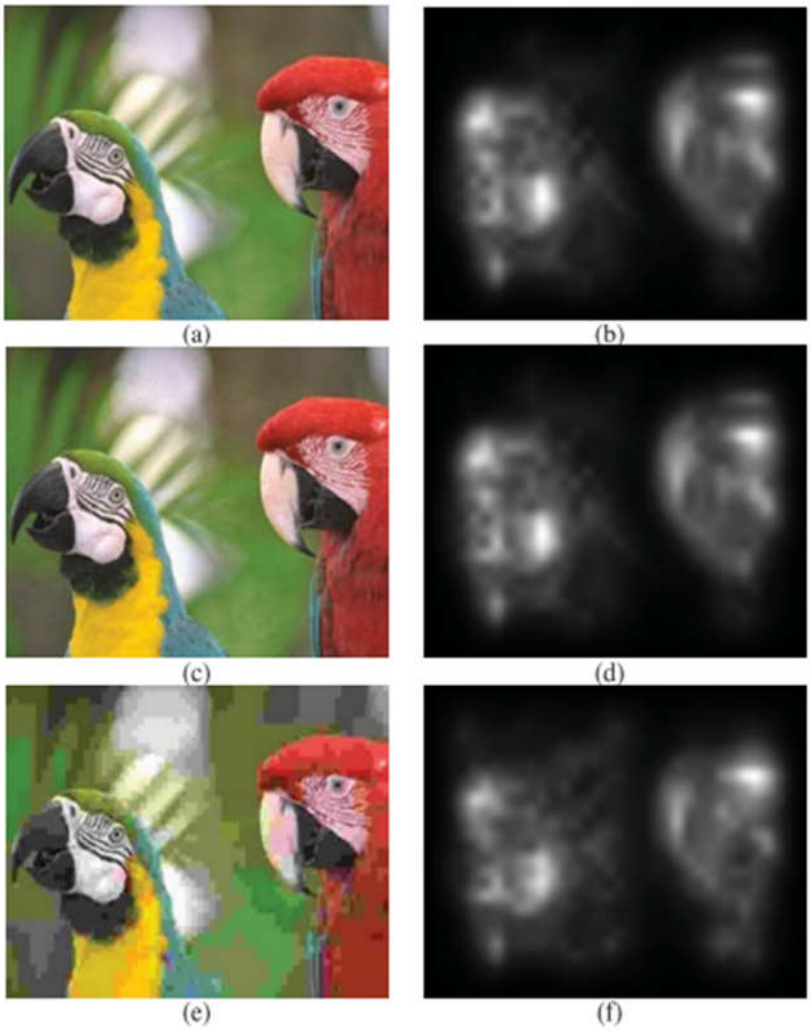

Sl. 3.1. *(a) je originalna slika, (b) VS mapa originalne slike, (c) slika s prvom vrstom deformacije,(d) VS mapa slike s prvom vrstom deformacije, (e) slika s drugom vrstom deformacije, (f) VS mapa slike s drugom vrstom deformacije, [21].*

Na temelju provedene analize može se primijetiti da u većini slučajeva promjena kod VS mapa može biti dobar pokazatelj za stupanj deformacije i stoga se predlaže korištenje VS mapa kao svojstvo za opisivanje lokalne kvalitete slike. Iz tablice 3.1 može se vidjeti da kao pokazatelj kvalitete deformacije, VS mapa ne radi dobro za vrstu deformacije CTC (engl. *Contrast Change*). Glavni razlog je da zbog operacije normalizacije umiješane u VS računalni model, vrijednost VS na elementu slike se mjeri da bi se održavala njegova relativna posebnost u okolini, koja čini VS nemoćnim za opisivanje apsolutnog kontrast slike. Usprkos tome, lokalni kontrast slike ne utječe previše na zapažanje kvalitete slike kod ljudi.

Za primjer se koristi sl. 3.2 kako bi se opisala ova činjenica. Sl. 3.2.(a) je referentna slika, dok sl. 3.2.(b) je deformirana verzija referentne slike, a vrsta deformacije je smanjenje kontrasta. Sl. 3.2.(c) i sl. 3.2.(d) su VS mape od sl. 3.2.(a) i sl. 3.2.(b), za svaku posebno, korištenjem GBVS

modela [29]. Sl. 3.2.(e) i sl. 3.2.(f) su GM mapa izračunata iz sl. 3.2.(a) i sl. 3.2.(b) za svaku posebno, korištenjem operatorom Scharr-ovog gradijenta. Lako se može vidjeti da sl. 3.2.(b) ima lošiju kvalitetu od sl. 3.2.(a). Iako je takvo smanjenje kvalitete izazvano smanjenjem kontrasta, ne može utjecati na VS mape, s obzirom da se ne mogu primijetiti znatne razlike između sl. 3.2.(c) i sl. 3.2.(d). Jasna razlika kontrasta može se primijetiti između sl. 3.2.(e) i sl. 3.2.(f), što upućuje da GM mapa ima dobru sposobnost u detekciji lokalnog kontrasta prigušenog na slici.

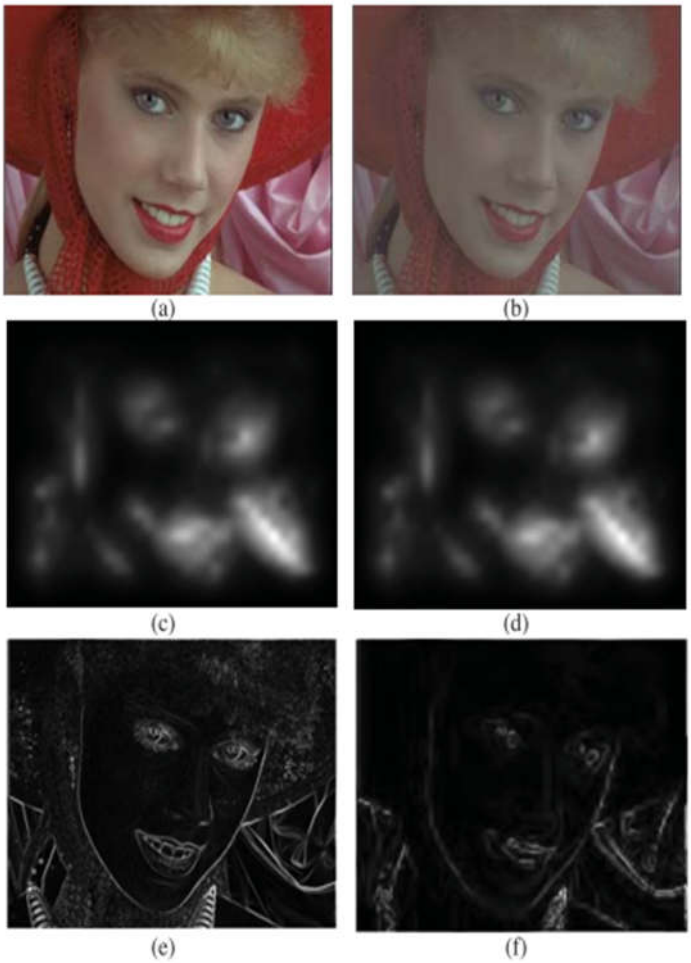

Sl. 3.2. *(a) Referentna slika, (b) deformirana verzija referentne slike, a vrsta deformacije je smanjenje kontrasta, (c) VS mapa slike (a), (d) VS mapa slike (b) [2]*

Na svu sreću, mogu se koristiti dodatni elementi kako bi se nadopunio nedostatak osjetljivosti na kontrast kod VS. Najjednostavniji dodatak takve vrste je gradijentni modul GM *(*engl. *Gradient modulus)*. Postoji nekoliko različitih operatora za računanje gradijenta slika, kao što su Prewitt-ov operator, Sobel-ov operator, Robert-ov operator [30] i Scharr-ov operator [31]. U radu će se koristiti Scharr-ov gradijentni operator koji se pokazao vrlo dobrim.

Sa Scharr-ovim gradijentnim operatorom parcijalne derivacije $G_x(x)$ i $G_y(x)$ od slike $f(x)$ računaju se pomoću sljedećih izraza [21]:

$$G_x(x) = \frac{1}{16}\begin{bmatrix} 3 & 0 & 3 \\ 10 & 0 & 10 \\ 3 & 0 & 3 \end{bmatrix} \times f(x) \tag{3-1}$$

$$G_y(x) = \frac{1}{16}\begin{bmatrix} 3 & 10 & 3 \\ 0 & 0 & 0 \\ 3 & 10 & 3 \end{bmatrix} \times f(x) \tag{3-2}$$

GM od $f(x)$ se onda računa kao:

$$G(x) = \sqrt{G_x^2(x) + G_y^2(x)} \tag{3-3}$$

GM mape iz sl. 3.2(a) i sl. 3.2(b) prikazane su na sl. 3.2(e) i sl. 3.2(f), zasebno. Jasna razlika može se primijetiti između sl. 3.2(e) i sl. 3.2(f), te ukazuje da GM mapa ima dobru sposobnost u detekciji gubitka lokalnog kontrasta u slikama. VS i GM su komplementarne i one sadržavaju različite aspekte HVS-a da bi se detektirala lokalna kvaliteta testnih slika.

Iz tablice. 3.1 još se može vidjeti da VS mape ne rade najbolje kao pokazatelj kvalitete deformacije, za deformacije vrste CCS (engl. *Change of Color Saturation*). Deformacija boje ne može se dobro karakterizirati s gradijentom, jer se obično gradijent izračunava iz luminantne komponente slike. Stoga, da bi se napravila IQA metrika sa sposobnošću da se suoči s deformacijom boja, informacijama sjajnosti boje, trebalo bi tome dati posebno razmatranje. Postepeno bi RGB komponente slika trebalo prvo pretvoriti ih u LMN prostor boja [32]:

$$\begin{bmatrix} L \\ M \\ N \end{bmatrix} = \begin{bmatrix} 0.06 & 0.63 & 0.27 \\ 0.30 & 0.04 & 0.35 \\ 0.34 & 0.6 & 0.17 \end{bmatrix} \begin{bmatrix} R \\ G \\ B \end{bmatrix} \tag{3-4}$$

Vrijednosti za računanje optimizirane su za HVS [33]. Gradijent je izračunat iz kanala L, M i N, dva kanala za sjajnost boje, bit će korištena kao obilježja za prikaz smanjenja kvalitete izazvanog deformacijom boja.

S izdvojenim VS, GM i svojstvima svjetlosti boje, može se definirati indeks baziran na VS ili jednostavnije VSI (engl. *Visual Saliency –based index*) za zadatke IQA. Pretpostavlja se da će se računati sličnost između slika f_1 i f_2 . Neka su VS_1 i VS_2 dvije VS mape izdvojene iz slika f_1 i f_2 koristeći posebni VS model, te neka su G_1 i G_2 dvije GM mape, M_1 i M_2 dva M kanala, a N_1 i N_2 dva N kanala. Računanje VSI sastoji se od dva dijela. U prvom dijelu izračuna se lokalna sličnost mapa, a u drugom se udružuje sličnost mapa u jedinstvenu ocjenu kvalitete. Odvaja se mjera

sličnosti između $f_1(x)$ i $f_2(x)$ u tri komponente, jedna za VS, druga za GM i treće za svjetlost boje. Prvo, sličnost između $VS_1(x)$ i $VS_2(x)$ definira se kao :

$$S_{VS}(x) = \frac{2VS_1(x)\ VS_2(x)+C_1}{VS_1^2(x)+VS_2^2(x)+C_1}, \tag{3-5}$$

gdje je C_1 pozitivna konstanta za povećanje stabilnosti S_{VS}. Slično se uspoređuju GM vrijednosti $G_1(x)$ i $G_2(x)$:

$$S_G(x) = \frac{2G_1(x)\ \ G_2(x) + C_2}{G_1^2(x) + G_2^2(x) + C_2} \tag{3-6}$$

gdje je C_2 druga pozitivna konstanta. Sličnost između komponenti svjetlosti boja definira se kao:

$$S_C(x) = \frac{2M_1(x)\ \ M_2(x) + C_3}{M_1^2(x) + M_2^2(x) + C_3}\ \ \frac{2N_1(x)\ \ N_2(x) + C_3}{N_1^2(x) + N_2^2(x) + C_3} \tag{3-7}$$

U eksperimentu C_1, C_2 i C_3 su podešeni tako da predloženi VSI može biti jednostavno primijenjen za sve baze podataka. Zato $S_{VS}(x)$, $S_G(x)$ i $S_C(x)$ kombiniraju da bi se dobila lokalna sličnost $S(x)$ između $f_1(x)$ i $f_2(x)$. Prema tome, $S(x)$ se definira na sljedeći način:

$$S(x) = S_{VS}(x)\ \ [S_G(x)]^{\alpha}\ \ [S_C(x)]^{\beta}, \tag{3-8}$$

gdje su α i β dva parametra korištena za prilagodbu relativne važnosti za VS, GM i sjajnost boje. Ako postoji lokalna sličnost $S(x)$ na svakoj lokaciji x, cjelokupna sličnost između f_1 i f_2 može se izračunati prema (3-9):

$$VSI = \frac{\sum_{\Omega} S_{VS}(x)\ \ [S_G(x)]^{\alpha}\ \ [S_C(x)]^{\beta}\ \ VS_m(x)}{\sum_{\Omega} VS_m(x)} \tag{3-9}$$

Pokazano je da različita lokacija može imati različiti utjecaj na HVS pri sagledavanja kvalitete slike i da bi bilo bolje kada bi strategija udruživanja rezultata bila povezana s ljudskom vizualnom pažnjom. Stoga, u VSI okosnici prirodno je da se odabere VS mapa za opisivanje vizualne važnosti lokalnog područja. Intuitivno, za danu poziciju x, ako jedna od $f_1(x)$ i $f_2(x)$ ima veliku vrijednost VS-a, smatra se da će ta pozicija x, imati snažan učinak na HVS, kada se računa sličnost između f_1 i f_2. Zato se koristi $VS_m(x)=max(VS_1(x), VS_2(x))$ za računanje važnosti $S(x)$ u konačnoj sličnosti. Konačno, VSI metrika između f_1 i f_2 definira se kao:

$$VSI = \frac{\sum_{x\in\Omega} S(x) \;\; VS_m(x)}{\sum_{x\in\Omega} VS_m(x)} \tag{3-10}$$

gdje Ω označava cijelu prostornu domenu. Može se lako potvrditi da funkcija VSI metrike zadovoljava svojstva spomenuta u [13], a procedura računanja VSI prikazana je primjerom na sl. 3.3.

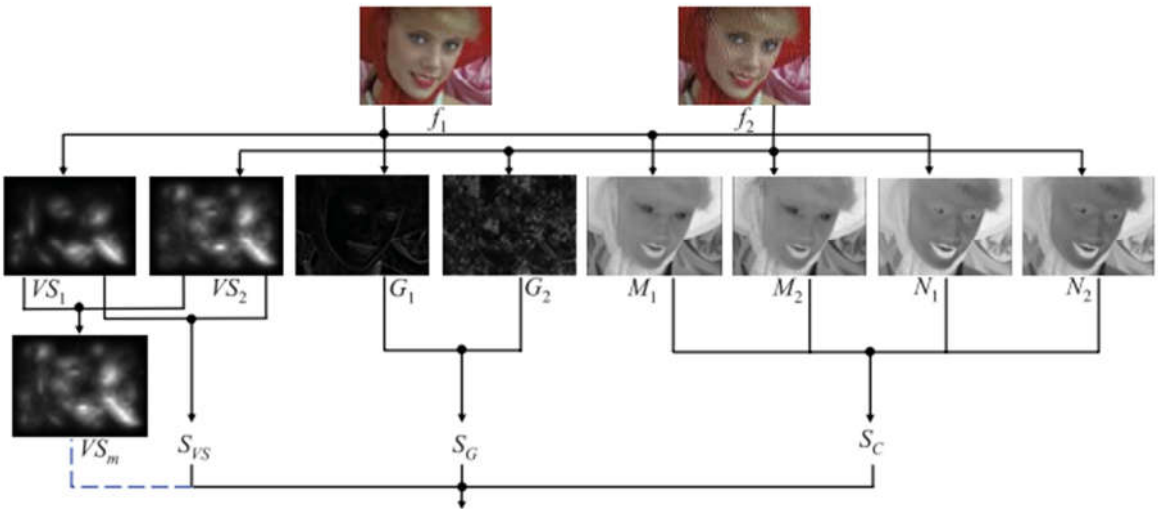

Sl. 3.3 *Računalni proces predložen za IQA pomoću VSI indeksa, gdje je f_1 referentna slika, a f_2 je izobličena verzija f_1 [2]*

4. OCJENA KVALITETE SLIKE RAZLIČITIM METRIKAMA

Ocjenu kvalitete slike moguće je provesti na dva načina, a to su subjektivna i objektivna procjena kvalitete slike. Subjektivna ocjena kvalitete slike temelji se na eksperimentu gdje kvalitetu slike procjenjuju i rangiraju ljudi. Rezultat ovakvog eksperimenta ovisi o psiho-vizualnoj percepciji svakog čovjeka zasebno, te ovisi o nekoliko parametara: uvjeti u kojim je vršen eksperiment, raspoloženje promatrača… Subjektivna metoda je skupa, nezgodna za osmisliti i zahtijeva puno vremena, ali zato je najbolji način da se razumije osnovna percepcija kvalitete, te daje korisne informacije za naknadne faze modeliranja. Objektivne metode ocjenjuju kvalitete slike pomoću nekog računalnog modela. Objektivne metode koje će se koristiti za procjenu kvalitetu slike su PSNR i SSIM metode koje su prije spomenute, kao i VSI metrika, koja je objašnjena u 3. poglavlju. Uspoređivat će se ocjene ljudi, ocjene PSNR, SSIM i ocjene VSI metrike.

4.1. Baza testnih slika

Baza podataka za koju će se vršiti ocjenjivanje naziva se VCL@FER baza podataka [34]. VCL@FER baza podataka sastoji se od 552 slike, od koji su 23 originalne, 4 različita tipa izobličenja po slici i sa 6 stupnjeva količine izobličenja po pojedinom tipu.

Tipovi izobličenja kvalitete su:

- JPEG2000
- JPEG
- Gaussov šum
- Bijeli šum

U ovom radu neće se koristiti sve 552 slike nego 207 slika, a to su 23 originalne slike s 3 različita tipa izobličenja i s 3 stupnja količine izobličenja po pojedinom tipu.

Tipovi izobličenja kvalitete koja će se koristiti u ovom radu su:

- JPEG2000 (kasnije u radu u svom imenu sadrži sufiks „J2K“)
- JPEG (kasnije u radu u svom imenu sadrži sufiks „JPG“)
- Gaussov šum(kasnije u radu u svom imenu sadrži sufiks „BLU“)

Eksperiment subjektivne procjene kvalitete za cijelu VCL@FER bazu se izvršio uz 118 subjekata koji su morali ocijeniti sveukupno 11307 slika. Svaka slika procijenjena je između 16 i 36 puta.

Svaki subjekt morao je ocijeniti različite vrste smanjenja kvalitete. Rezultat srednje subjektivne ocjene MOS (engl. *Mean Opinion Score*) računat je u skladu sa *ITU-R BT.500-11* [35]. U nastavku se nalaze 23 originalne slike koje su se koristile u eksperimentu. Slike i opis baze podataka preuzeti su sa [34].

a)

b)

c)

d)

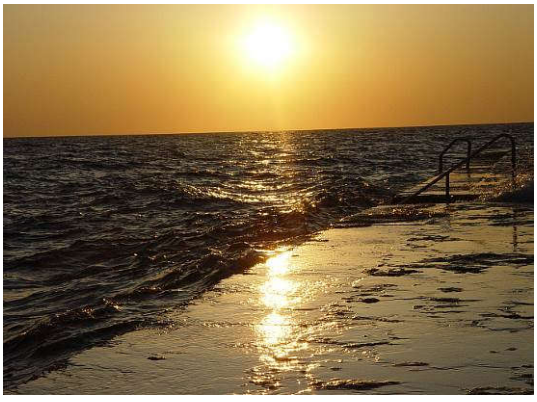

e)

f)

Sl. 4.1. *Slike iz VLC@FER baze podataka a) IMG_01, b) IMG_02, c) IMG_03, d) IMG_04, e) IMG_05 f) IMG_06, [34]*

a)

b)

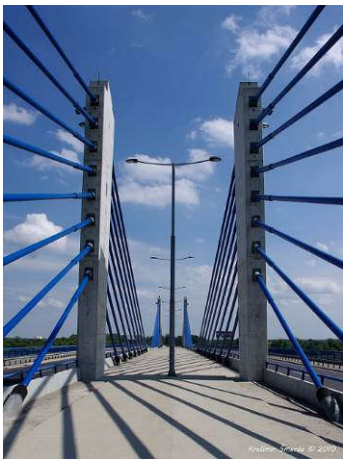

c)

d)

e)

f)

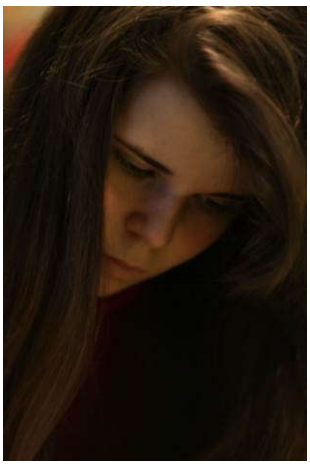

g)

h)

Sl. 4.2 *Slike iz VLC@FER baze podataka a) IMG_07, b) IMG_08, c) IMG_09, d) IMG_10, e) IMG_11, f) IMG_12, h) IMG_13, g) IMG_18, [34]*

a)

b)

c)

d)

e)

f)

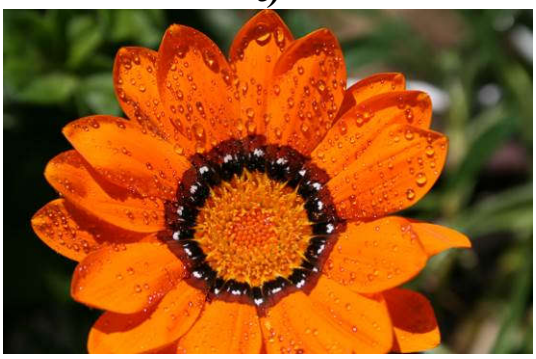

h)

Sl. 4.3 *Slike iz VLC@FER baze podataka a) IMG_147, b) IMG_15, c) IMG_16, d) IMG_17, e) IMG_19, f) IMG_20, h) IMG_21, [34]*

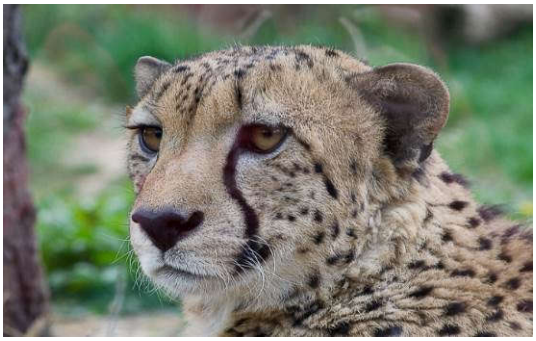

a) ***b)***

Sl. 4.4 *Slike iz VLC@FER baze podataka a) IMG_22, b) IMG_23, [34]*

4.2. Opis ocjene kvalitete VSI metrikom

Izvorni kod VSI metrike preuzet je u obliku MATLAB-ove m-datoteke koji se nalazi na [36]. MATLAB kod za VSI metriku može se pokrenuti dvostrukim klikom na m-datoteku VSI metrike. Kada se program pokrene u MATLAB-u, otvore se dva prozora. Jedan prozor je standardni MATLAB prozor u kojem se nalaze dodatni prozori od kojih se u ovom eksperimentu koristi komandni prozor (engl. *Command Window*), koji je vidljiv na sl. 4.5 i on služi za pozivanje funkcije za izračun VSI i radni prostor (engl. *Workspace*) u koji se dodaju slike za usporedbu, te alatna traka. Drugi prozor koji se otvori je MATLAB prozor u kojem su napisane funkcije, koje se pozivaju u komandnom prozoru (engl. *MATLAB Editor*). Kod funkcije vidljiv je u tom prozoru, koji se može vidjeti na sl. 4.6.

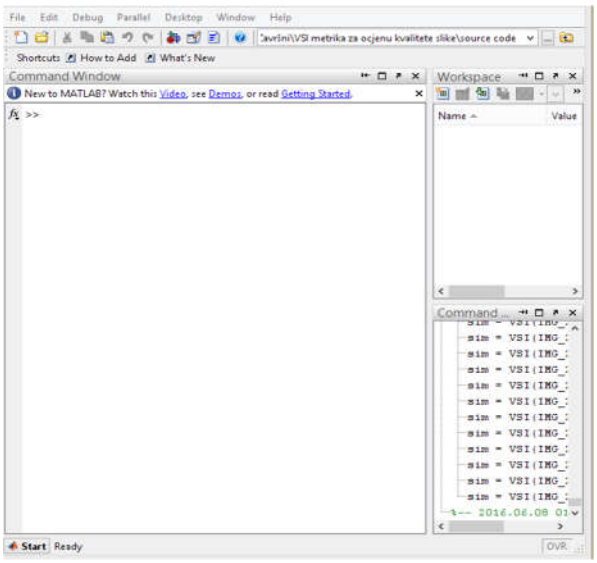

Sl. 4.5. *Prikaz MATLAB prozora pri pokretanju programa.*

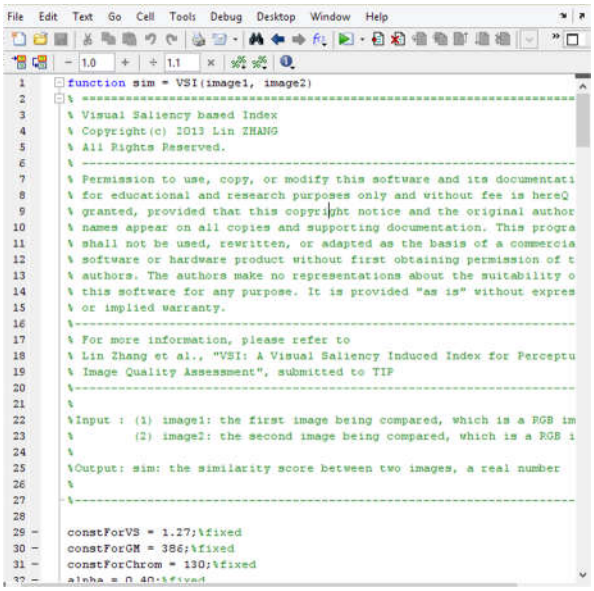

Sl. 4.6. *Prikaz MATLAB Editor-a pri pokretanju programa.*

Kako bi se slike mogle koristiti za obradu u MATLABU i kako bi ih program mogao prepoznati, one se moraju dodati u program. Sve slike iz baze podataka nalaze se u jednoj mapi koja se može vidjeti na Sl. 4.7. Slike iz baze podataka dodaju se u radni prostor (engl. *Workspace)*. Dodavanje se može izvršiti na dva načina: prvi je da se u radnom prostoru pritisne ikonica „uvezi datoteku“ (engl., *Import data*), te se ona pronađe u mapi u kojoj su smještene slike iz baze podataka, dok je drugi način nešto jednostavniji, u kojemu se samo slika iz mape „prevuče“ u radni prostor. U oba slučaja pojavit će se prozor „čarobnjak uvoza“ (engl. *Import Wizard*) koji je vidljiv na Sl. 4.8. na kojemu se mora samo potvrditi sa tipkom „završetak“ (engl. *Finish).*

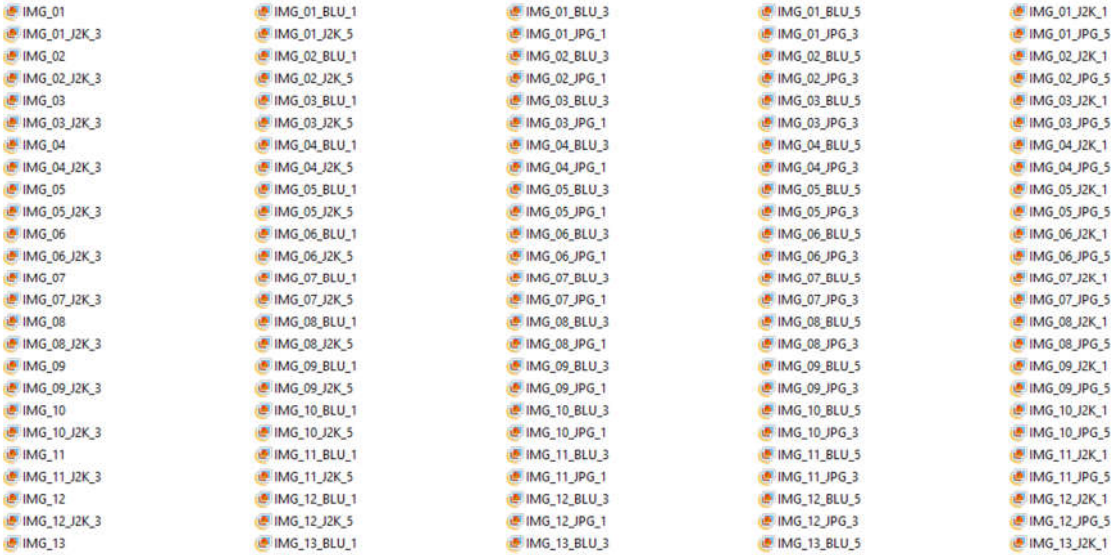

Sl. 4.7. *Prikaz slika iz baze podataka u jednoj mapi*

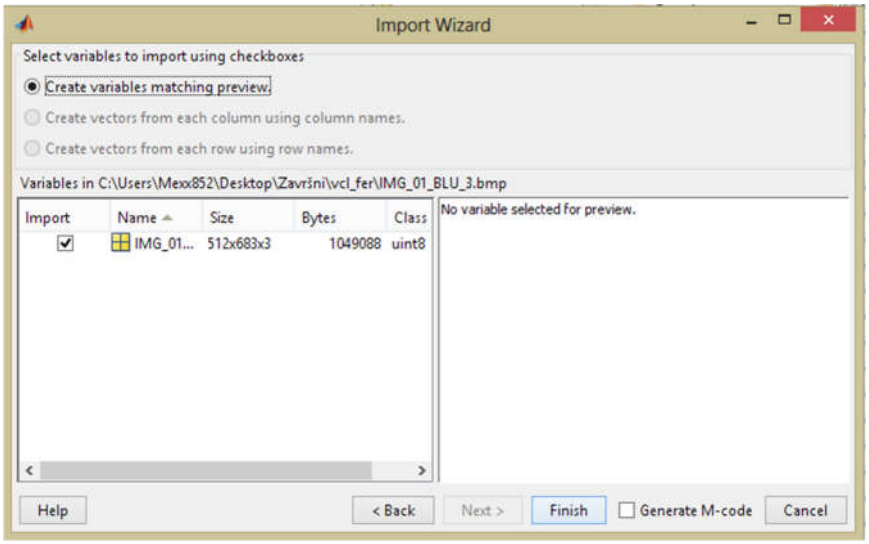

Sl. 4.8. *Prikaz prozora „čarobnjaka uvoza“ za sliku IMG_01.*

Dodavanje slika mora se izvršiti pojedinačno, što je malo dugotrajniji proces. Kada se unese jedna slika sa svim njezinim deformacijama kao na Sl. 4.9., može se krenuti s pozivanjem funkcije za dobivanje VSI ocjene. Funkcija se poziva upisivanjem naredbe u komandni prozor koja izgleda: *sim=VSI(slika1, slika2)*; gdje *slika1* predstavlja referentnu sliku bez izobličenja, a *slika2* predstavlja sliku s nekom vrstom i stupnjem izobličenja.

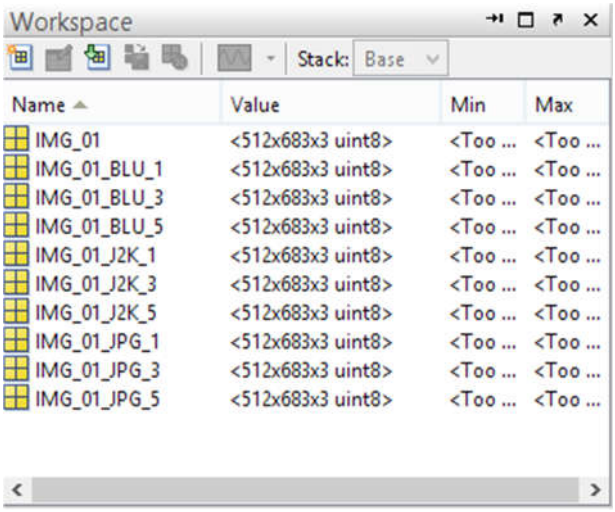

Sl. 4.9. *Unesena referentna slika, sa svim svojim izobličenjima.*

Program radi tako da uspoređuje sličnost između referentne slike i izobličene slike, te rezultat prikazuje u rasponu od 0 do 1, gdje je 1 potpuna sličnost, a 0 potpuna različitost. Kada se poziva funkcija, umjesto *slike1* upisuje se točan naziv referentne slike, a za *sliku2* se upisuje točan naziv slike s izobličenjem koju želimo usporediti s referentnom slikom. Na sl. 4.10 može se vidjeti kako je funkcija pozvana i kako ispisuje njihovu sličnost.

```
>> sim=VSI(IMG_01, IMG_01_BLU_1)

sim =

    0.9995

>> sim=VSI(IMG_01, IMG_01_J2K_1)

sim =

    0.9989

>> sim=VSI(IMG_01, IMG_01_JPG_1)

sim =

    0.9973

fx >>
```

Sl. 4.10. *Pozivanje funkcije za usporedbu dviju slika VSI metrikom.*

U prozoru gdje se nalaze komandni i radni prozor postoji još jedan prozor sa svim funkcijama koje su se kroz povijest u komadnom prozoru koristile. Taj prozor zove se povijest komandi (engl. *Command History*). Na Sl. 4.11 može se vidjeti nekoliko različitih funkcija koje su se koristile u ovom eksperimentu.

```
Command History
    sim = VSI(IMG_01, IMG_01_BLU_1)
    sim = VSI(IMG_01, IMG_01_BLU_2)
    sim = VSI(IMG_01, IMG_01_BLU_3)
    sim = VSI(IMG_01, IMG_01_BLU_5)
    sim = VSI(IMG_01, IMG_01_J2K_1)
    sim = VSI(IMG_01, IMG_01_J2K_3)
    sim = VSI(IMG_01, IMG_01_J2K_5)
    sim = VSI(IMG_01, IMG_01_JPG_1)
    sim = VSI(IMG_01, IMG_01_JPG_3)
    sim = VSI(IMG_01, IMG_01_JPG_5)
    sim = VSI(IMG_02, IMG_02_BLU_1)
    sim = VSI(IMG_02, IMG_02_BLU_3)
    sim = VSI(IMG_02, IMG_02_BLU_5)
    sim = VSI(IMG_02, IMG_02_J2K_1)
    sim = VSI(IMG_02, IMG_02_J2K_3)
```

Sl. 4.11 *Dio funkcija koje su korištene u eksperimentu.*

U Tablici. 4.1. dani su rezultati subjektivne ocjene za odabrane slike iz VCL@FER baze (MOS) te rezultati dobiveni PSNR i SSIM i VSI metrikom. PSNR je računat u MATLAB-u pomoću gotove funkcije, a SSIM je također računat u MATLAB-u pomoću koda preuzetog sa [37,38].

Tablica. 4.1. *Rezultati subjektivne i objektivne ocjene odabranih slika iz VCL@FER baze*

Redni broj	Naziv slike	MOS	PSNR [dB]	SSIM	VSI
1.	IMG_01	56,9	100	1	1
2.	IMG_01_BLU_1	67,3	35,463	0,991	1
3.	IMG_01_BLU_3	59,7	21,536	0,688	0,987
4.	IMG_01_BLU_5	26,4	17,655	0,230	0,886
5.	IMG_01_J2K_1	67,1	31,845	0,974	0,999
6.	IMG_01_J2K_3	46,6	20,727	0,655	0,978
7.	IMG_01_J2K_5	16,9	18,35	0,368	0,934
8.	IMG_01_JPG_1	66,1	30,093	0,961	0,997
9.	IMG_01_JPG_3	56,9	23,175	0,821	0,991
10.	IMG_01_JPG_5	31,3	21,006	0,699	0,979
11.	IMG_02	66,9	100	1	1
12.	IMG_02_BLU_1	74,5	38,918	0,993	1
13.	IMG_02_BLU_3	44,9	22,549	0,690	0,983
14.	IMG_02_BLU_5	18,6	20,869	0,450	0,922
15.	IMG_02_J2K_1	68	42,596	0,976	1
16.	IMG_02_J2K_3	40,2	26,989	0,740	0,988
17.	IMG_02_J2K_5	15,2	23,235	0,559	0,965
18.	IMG_02_JPG_1	65,2	34,059	0,914	0,997
19.	IMG_02_JPG_3	52	27,86	0,777	0,988
20.	IMG_02_JPG_5	19,2	25,325	0,658	0,971
21.	IMG_03	74,4	100	1	1
22.	IMG_03_BLU_1	80,5	38,918	0,991	1
23.	IMG_03_BLU_3	37,1	22,549	0,549	0,965
24.	IMG_03_BLU_5	16,8	20,869	0,414	0,92
25.	IMG_03_J2K_1	85	42,596	0,993	1
26.	IMG_03_J2K_3	46,9	26,989	0,777	0,991
27.	IMG_03_J2K_5	23,4	23,235	0,578	0,967
28.	IMG_03_JPG_1	73	34,059	0,945	0,998
29.	IMG_03_JPG_3	51,5	27,86	0,827	0,993
30.	IMG_03_JPG_5	38,2	10,045	0,721	0,981
31.	IMG_04	73,8	100	1	1
32.	IMG_04_BLU_1	78,3	37,738	0,994	1
33.	IMG_04_BLU_3	40,3	20,995	0,638	0,966
34.	IMG_04_BLU_5	14,8	17,395	0,281	0,851
35.	IMG_04_J2K_1	79,2	34,922	0,981	0,999
36.	IMG_04_J2K_3	42,2	22,544	0,732	0,974
37.	IMG_04_J2K_5	23,4	19,07	0,453	0,923
38.	IMG_04_JPG_1	73,8	32,007	0,962	0,996
39.	IMG_04_JPG_3	50	25,653	0,865	0,988
40.	IMG_04_JPG_5	38,3	23,173	0,768	0,976
41.	IMG_05	74	100	1	1
42.	IMG_05_BLU_1	78,9	38,122	0,990	1
43.	IMG_05_BLU_3	32,5	22,357	0,558	0,963
44.	IMG_05_BLU_5	20,1	21,127	0,464	0,92
45.	IMG_05_J2K_1	68,4	40,009	0,977	1
46.	IMG_05_J2K_3	64	26,816	0,798	0,99
47.	IMG_05_J2K_5	21,8	23,174	0,623	0,972
48.	IMG_05_JPG_1	78,2	33,584	0,939	0,997
49.	IMG_05_JPG_3	47,8	27,285	0,831	0,99
50.	IMG_05_JPG_5	18,6	24,946	0,732	0,976
51.	IMG_06	88	100	1	1
52.	IMG_06_BLU_1	91,4	37,58	0,993	1
53.	IMG_06_BLU_3	47,6	21,079	0,655	0,96
54.	IMG_06_BLU_5	23	18,419	0,416	0,882
55.	IMG_06_J2K_1	85,1	40,547	0,984	1
56.	IMG_06_J2K_3	48,7	24,524	0,784	0,98
57.	IMG_06_J2K_5	19,6	21,122	0,579	0,942
58.	IMG_06_JPG_1	77,7	38,814	0,953	0,995
59.	IMG_06_JPG_3	57,5	27,126	0,854	0,986
60.	IMG_06_JPG_5	35,6	24,443	0,755	0,973
61.	IMG_07	75,2	100	1	1
62.	IMG_07_BLU_1	75,9	39,429	0,992	1
63.	IMG_07_BLU_3	41,5	23,635	0,593	0,971
64.	IMG_07_BLU_5	22,1	21,812	0,454	0,924
65.	IMG_07_J2K_1	83,9	39,485	0,975	1
66.	IMG_07_J2K_3	49,3	26,897	0,753	0,987
67.	IMG_07_J2K_5	29,8	23,876	0,580	0,965
68.	IMG_07_JPG_1	76,6	33,378	0,925	0,997
69.	IMG_07_JPG_3	62,3	27,575	0,792	0,989
70.	IMG_07_JPG_5	27,6	25,336	0,678	0,972
71.	IMG_08	77,9	100	1	1
72.	IMG_08_BLU_1	82	39,226	0,992	1
73.	IMG_08_BLU_3	44,9	23,29	0,601	0,968
74.	IMG_08_BLU_5	24,2	21,629	0,457	0,918
75.	IMG_08_J2K_1	75,2	44,014	0,990	1
76.	IMG_08_J2K_3	57,2	28,958	0,816	0,99
77.	IMG_08_J2K_5	30,7	24,324	0,623	0,968
78.	IMG_08_JPG_1	73,9	35,167	0,947	0,998
79.	IMG_08_JPG_3	51,6	29,167	0,840	0,991
80.	IMG_08_JPG_5	31,3	26,51	0,732	0,975
81.	IMG_09	82	100	1	1
82.	IMG_09_BLU_1	90,4	40,711	0,995	1
83.	IMG_09_BLU_3	44,6	23,521	0,803	0,973
84.	IMG_09_BLU_5	21,6	20,612	0,655	0,923
85.	IMG_09_J2K_1	84,1	49,193	0,993	1
86.	IMG_09_J2K_3	52,1	31,357	0,916	0,993
87.	IMG_09_J2K_5	24,6	25,032	0,778	0,965
88.	IMG_09_JPG_1	76,9	37,098	0,964	0,998
89.	IMG_09_JPG_3	51,2	30,519	0,92	0,991
90.	IMG_09_JPG_5	28,1	27,429	0,840	0,979
91.	IMG_10	85,2	100	1	1
92.	IMG_10_BLU_1	87,7	35,213	0,993	0,999
93.	IMG_10_BLU_3	35,8	19,778	0,765	0,965
94.	IMG_10_BLU_5	24,6	18,557	0,689	0,915
95.	IMG_10_J2K_1	89,1	43,809	0,993	1
96.	IMG_10_J2K_3	73,3	30,004	0,961	0,996
97.	IMG_10_J2K_5	25,8	21,054	0,814	0,969
98.	IMG_10_JPG_1	81,2	32,89	0,978	0,998
99.	IMG_10_JPG_3	55,8	27,537	0,944	0,993
100.	IMG_10_JPG_5	32,7	24,278	0,903	0,98
101.	IMG_11	89,7	100	1	1
102.	IMG_11_BLU_1	86,7	43,204	0,991	1
103.	IMG_11_BLU_3	53,9	26,511	0,909	0,991
104.	IMG_11_BLU_5	26,7	23,736	0,849	0,976
105.	IMG_11_J2K_1	88,9	51,189	0,986	1
106.	IMG_11_J2K_3	76,4	34,162	0,942	0,999
107.	IMG_11_J2K_5	42,4	27,804	0,814	0,99
108.	IMG_11_JPG_1	65,7	33,924	0,992	0,998
109.	IMG_11_JPG_3	47,5	29,899	0,921	0,994
110.	IMG_11_JPG_5	33,5	27,332	0,855	0,985
111.	IMG_12	75,1	100	1	1
112.	IMG_12_BLU_1	80,2	42,829	0,996	1
113.	IMG_12_BLU_3	51,3	26,155	0,886	0,988
114.	IMG_12_BLU_5	29,8	23,02	0,815	0,963
115.	IMG_12_J2K_1	84,5	54,509	0,997	1
116.	IMG_12_J2K_3	71,4	33,539	0,954	0,998
117.	IMG_12_J2K_5	36,4	27,482	0,889	0,998
118.	IMG_12_JPG_1	69	34,6	0,963	0,999
119.	IMG_12_JPG_3	53,8	29,745	0,914	0,993
120.	IMG_12_JPG_5	30,0,	27,253	0,854	0,981

121.	IMG_13	80,2	100	1	1
122.	IMG_13_BLU_1	80,6	50,583	0,996	1
123.	IMG_13_BLU_3	58	36,985	0,932	0,998
124.	IMG_13_BLU_5	33	32,391	0,877	0,991
125.	IMG_13_J2K_1	73,5	44,152	0,992	1
126.	IMG_13_J2K_3	71,7	39,11	0,965	0,999
127.	IMG_13_J2K_5	47,3	37,065	0,936	0,997
128.	IMG_13_JPG_1	71,3	38,325	0,964	0,999
129.	IMG_13_JPG_3	39,5	35,028	0,921	0,994
130.	IMG_13_JPG_5	18,7	31,645	0,869	0,982
131.	IMG_14	69,7	100	1	1
132.	IMG_14_BLU_1	82,6	34,909	0,992	1
133.	IMG_14_BLU_3	36,9	18,696	0,574	0,971
134.	IMG_14_BLU_5	26,5	17,216	0,419	0,92
135.	IMG_14_J2K_1	74,4	37,382	0,979	0,999
136.	IMG_14_J2K_3	44,7	21,076	0,738	0,986
137.	IMG_14_J2K_5	16,8	18,77	0,537	0,961
138.	IMG_14_JPG_1	70,6	32,264	0,955	0,998
139.	IMG_14_JPG_3	55,6	23,907	0,847	0,992
140.	IMG_14_JPG_5	23,8	21,459	0,743	0,981
141.	IMG_15	76,5	100	1	1
142.	IMG_15_BLU_1	82,9	47,789	0,996	1
143.	IMG_15_BLU_3	37,4	30,24	0,896	0,99
144.	IMG_15_BLU_5	23,8	26,065	0,794	0,962
145.	IMG_15_J2K_1	83,4	55,918	0,997	1
146.	IMG_15_J2K_3	61,2	37,287	0,958	0,998
147.	IMG_15_J2K_5	31,6	31,6	0,882	0,987
148.	IMG_15_JPG_1	77	39,731	0,972	0,999
149.	IMG_15_JPG_3	53,6	34,569	0,927	0,994
150.	IMG_15_JPG_5	27	31,521	0,876	0,984
151.	IMG_16	72,9	100	1	1
152.	IMG_16_BLU_1	74	46,203	0,995	1
153.	IMG_16_BLU_3	37,7	27,317	0,841	0,98
154.	IMG_16_BLU_5	20,7	22,054	0,578	0,922
155.	IMG_16_J2K_1	70,9	47,001	0,997	1
156.	IMG_16_J2K_3	50,3	32,357	0,924	0,993
157.	IMG_16_J2K_5	29,1	26,613	0,761	0,966
158.	IMG_16_JPG_1	72,5	37,957	0,975	0,998
159.	IMG_16_JPG_3	41,6	32,65	0,921	0,993
160.	IMG_16_JPG_5	32,1	29,291	0,844	0,98
161.	IMG_17	81,4	100	1	1
162.	IMG_17_BLU_1	84,1	39,175	0,994	1
163.	IMG_17_BLU_3	31	22,955	0,784	0,967
164.	IMG_17_BLU_5	17,4	21,27	0,679	0,916
165.	IMG_17_J2K_1	86,7	47,507	0,992	1
166.	IMG_17_J2K_3	66,6	28,472	0,899	0,993
167.	IMG_17_J2K_5	32,3	23,974	0,768	0,975
168.	IMG_17_JPG_1	73,3	35,522	0,962	0,997
169.	IMG_17_JPG_3	63,9	28,344	0,888	0,991
170.	IMG_17_JPG_5	30,7	25,93	0,813	0,981
171.	IMG_18	83,1	100	1	1
172.	IMG_18_BLU_1	84,9	37,51	0,993	1
173.	IMG_18_BLU_3	40,4	20,989	0,608	0,969
174.	IMG_18_BLU_5	27,1	18,406	0,408	0,911
175.	IMG_18_J2K_1	89,7	37,301	0,985	1
176.	IMG_18_J2K_3	48,2	23,584	0,750	0,983
177.	IMG_18_J2K_5	23,5	20,364	0,551	0,948
178.	IMG_18_JPG_1	73,9	30,072	0,940	0,997
179.	IMG_18_JPG_3	48,4	24,967	0,825	0,988
180.	IMG_18_JPG_5	31	22,745	0,725	0,972
181.	IMG_19	71,2	100	1	1
182.	IMG_19_BLU_1	82,3	51,886	0,997	1
183.	IMG_19_BLU_3	48,1	37,036	0,919	0,994
184.	IMG_19_BLU_5	28	31,039	0,840	0,975
185.	IMG_19_J2K_1	89,1	51,835	0,994	1
186.	IMG_19_J2K_3	78,8	41,448	0,955	0,998
187.	IMG_19_J2K_5	43,6	37,177	0,900	0,991
188.	IMG_19_JPG_1	81,8	42,243	0,965	0,999
189.	IMG_19_JPG_3	48,4	37,534	0,906	0,993
190.	IMG_19_JPG_5	25,9	34,034	0,829	0,977
191.	IMG_20	74,7	100	1	1
192.	IMG_20_BLU_1	77,7	46,528	0,997	1
193.	IMG_20_BLU_3	37,4	28,217	0,786	0,982
194.	IMG_20_BLU_5	23,9	23,969	0,566	0,934
195.	IMG_20_J2K_1	75,7	46,289	0,992	1
196.	IMG_20_J2K_3	52,4	32,555	0,897	0,993
197.	IMG_20_J2K_5	31,6	27,667	0,704	0,968
198.	IMG_20_JPG_1	69	38,427	0,968	0,997
199.	IMG_20_JPG_3	41,9	32,717	0,894	0,991
200.	IMG_20_JPG_5	25,8	29,405	0,795	0,977
201.	IMG_21	62,1	100	1	1
202.	IMG_21_BLU_1	96,5	42,84	0,995	1
203.	IMG_21_BLU_3	45,9	25,999	0,786	0,977
204.	IMG_21_BLU_5	32,3	23,39	0,658	0,932
205.	IMG_21_J2K_1	94,4	44,95	0,990	1
206.	IMG_21_J2K_3	79,8	28,999	0,875	0,991
207.	IMG_21_J2K_5	27,9	25,697	0,736	0,968
208.	IMG_21_JPG_1	84,3	35,392	0,957	0,996
209.	IMG_21_JPG_3	66,3	29,755	0,877	0,99
210.	IMG_21_JPG_5	46,3	27,486	0,793	0,977
211.	IMG_22	69,6	100	1	1
212.	IMG_22_BLU_1	72,6	38,48	0,992	1
213.	IMG_22_BLU_3	51,5	22,978	0,633	0,978
214.	IMG_22_BLU_5	37,1	21,619	0,537	0,942
215.	IMG_22_J2K_1	79,4	42,898	0,983	1
216.	IMG_22_J2K_3	55,5	25,124	0,786	0,991
217.	IMG_22_J2K_5	31,7	22,929	0,639	0,973
218.	IMG_22_JPG_1	65,8	32,539	0,942	0,999
219.	IMG_22_JPG_3	51,5	25,495	0,812	0,992
220.	IMG_22_JPG_5	27,3	23,686	0,696	0,977
221.	IMG_23	89,7	100	1	1
222.	IMG_23_BLU_1	82,9	43,68	0,994	1
223.	IMG_23_BLU_3	45,6	26,768	0,729	0,982
224.	IMG_23_BLU_5	24,2	23,383	0,581	0,944
225.	IMG_23_J2K_1	90,1	42,483	0,980	1
226.	IMG_23_J2K_3	62,1	30,313	0,833	0,992
227.	IMG_23_J2K_5	26,7	26,684	0,664	0,971
228.	IMG_23_JPG_1	80,8	32,225	0,930	0,997
229.	IMG_23_JPG_3	48,2	30,348	0,831	0,99
230.	IMG_23_JPG_5	32	27,954	0,733	0,976

4.3. Diskusija o rezultatima

Obzirom da je velik broj slika na kojima je izvršeno ispitivanje subjektivnom i objektivnim metodama, najjednostavniji način da se usporede rezultati PSNR, SSIM i VSI metrike u odnosu

na subjektivnu MOS metodu je korištenjem Pearsonovog linearnog koeficijenta korelacije. Taj koeficijent se koristi kada postoji linearna povezanost između metoda, te se na temelju rezultata u jednoj metrici mogu predvidjeti rezultati druge metrike. Zbog toga što se ocjenama slike dobivenim jednom metrikom ne mogu s potpunom sigurnošću pretpostaviti ocjene drugom metrikom, može se pretpostaviti da se ocjena slike može kretati u određenom intervalu. Interval će biti manji što je koeficijent korelacije bliži 1, odnosno veći što je bliži 0. To znači gdje je veća subjektivna ocjena, najvjerojatnije će objektivna ocjena biti bolja, ali to ne možemo znati samo na temelju subjektivne ocjene, koja sama po sebi ovisi o uvjetima u kojima je izvršeno ispitivanje i o samom načinu gledanja ispitanika na sliku kao i njegovom raspoloženju u tom trenutku. Pearsonov linearni koeficijent korelacije računa se pomoću formule:

$$r = \frac{\sum_{i=1}^{n} d_{xi} d_{yi}}{\sqrt{\sum_{i=1}^{n} {d_{xi}}^2 \ \sum_{i=1}^{n} {d_{yi}}^2}}, \tag{4-1}$$

$$d_{xi} = x_i \quad \bar{x} \tag{4-2}$$

$$d_{yi} = y_i \quad \bar{y} \tag{4-3}$$

gdje je :

- $\bar{x}$ srednja vrijednost varijable *x*, odnosno srednja ocjena prve metrike za signal *i*
- $\bar{y}$ srednja vrijednost varijable *y*, odnosno srednja ocjena druge metrike za signal *i*

U tablici 4.2. dani su rezultati Pearsonovog linearnog koeficijenta korelacije za 3 ispitane objektivne metrike u odnosu na MOS.

Tablica. 4.2 *Rezultati Pearsonovog linearnog koeficijenta korelacije za PSNR, SSIM i VSI metrike*

Metrika	**Pearsonov linearni koeficijent korelacije**
PSNR	0,56589
SSIM	0,81235
VSI	0,73835

Prema rezultatima iz tablice 4.2. vidi se da PSNR metrika ima najmanji Pearsonov linearni koeficijent korelacije, kako je i očekivano, zato što je to najjednostavnija metoda za procjenu kvalitete slike, gdje ocjena PSNR-a ovisi samo o MSE, za razliku od SSIM i VSI metrike koje računaju ocjenu prema više segmenata. Dobiveni koeficijent je dosta manji nego kod drugih

metrika, a to znači da rezultati PSNR-a ne odgovaraju najbolje MOS rezultatima. SSIM metrika ima veći Pearsonov koeficijent nego VSI metrika, što je iznenađujuće s obzirom da je VSI naprednija i trebala bi dati bolji rezultat. Međutim, kako rezultat ovisi o MOS ocjenama, tj. o tome kako su ljudski ispitanici ocijenili sliku prema svom mišljenu (a može se vidjeti u tablici 4.1. da u nekim slučajevima originalna slika ima manju MOS ocjenu od te iste slike s nekom deformacijom), moguće su i navedene razlike. Prema rezultatima VSI metrike može se doći do zaključka da se rezultati postupno smanjuju s većim stupnjem deformacije i da nema velikih razlika kao kod PSNR i SSIM metrika, što pokazuje da ta metrika uzima u obzir više segmenata za procjenu kvalitete slike, bez obzira na veći Pearsonov koeficijent korelacije za SSIM nego za VSI metriku, za odabrane slike iz VCL@FER baze podataka, VSI metrika je puno bolja za ocjenu kvalitete slike. To je potvrđeno brojnim drugim eksperimentima čiji se rezultati mogu naći u [21], gdje je VSI nadmašila i mnogo bolje metrike od PSNR i SSIM.

5. ZAKLJUČAK

Kvaliteta slika ocjenjuje se na dva načina. Prvi način je subjektivni način ocjenjivanja gdje se od ljudskih ispitanika traži da ocjene kvalitetu slike. Drugi način je objektivnim ocjenjivanjem, koji se sve više razvija jer je subjektivni način skup, te dugotrajan proces koji se ne može implementirati u aplikacije da procjenjuje kvalitetu slike u stvarnom vremenu. VSI metrika je objektivna metrika predstavljena za IQA, zasniva se na pretpostavci da je VS mapa slika u bliskoj vezi s opaženom kvalitetom. Promjena kod VS mapa može biti dobar pokazatelj za stupanj deformacije, zato se VS mape koriste kao svojstvo za opisivanje lokalne kvalitete slike. VSI metrika računa sličnost između dviju slika, te se računa u tri komponente VS, GM i svjetlosti boja. Kako bi se mogla vidjeti učinkovitost VSI metrike, napravljen je eksperiment u kojemu je za slike iz VCL@FER baze podataka, izračunata ocjena kvalitete slike pomoću PSNR i SSIM objektivnih metrika za procjenu kvalitete slike. Rezultati su uspoređeni s izračunatom vrijednosti kvalitete slika pomoću VSI metrike. Za te slike iz VCL@FER baze podataka, poznate su MOS subjektivne ocjene, koje u nekim slučajevima imaju manju MOS ocjenu originalnih slika od slika koje imaju nekakvu vrstu deformacije, što govori kako ljudi na temelju svog „ukusa“ ocjenjuju slike. Zbog velikog broja ocjena za MOS, PSNR, SSIM i VSI, izračunata je korelacija ocjena pojedine objektivne metrike i MOS ocjene pomoću Pearsonovog koeficijenta korelacije. Prema rezultatima vidi se da PSNR ima najmanji koeficijent korelacije, što znači da rezultati prilično odstupaju od MOS-a. Iznenađujuće je što VSI ima manji koeficijent korelacije od SSIM metrike, budući da je VSI suvremenija i kompletnija metrika. No to je slučaj samo za ove odabrane slike iz VCL@FER baze. Na ostalim bazama iz literature VSI metrike pokazala se dominantnom nad spomenutim metrikama.

LITERATURA

[1] ITU-R Recommendation BT.500-11, "Methodology for the subjective assessment of the quality of television pictures," ITU, Geneva, Switzerland, 2002.

[2] R. Mantiuk, A. Tomaszewska, i R. Mantiuk, "Comparison of four subjective methods for image quality assessment," *Computer Graphics Forum*, vol. 31, str. 2478-2491, 2012.

[3] H. Gulliksen i L. R. Tucker, "A general procedure for obtaining paired comparisons from multiple rank orders," *Psychometrika*, vol. 26, str. 173-183, 1961.

[4] D. A. Silverstein i J. E. Farrell, "Efficient method for paired comparison," *J. Electron. Imag.*, vol. 10, str. 394-398, Travanj 2001.

[5] A. M. van Dijk, J.-B. Martens, i A. B. Watson, "Quality assessment of coded images using numerical category scaling," *Proc. SPIE*, vol. 2451, str. 90-101, 1995.

[6] P. Mohammadi, A. Ebrahimi-Moghadam i S. Shirani: „Subjective and Objective Quality Assessment of Image: A Survey“ , Department of Electrical Engineering Ferdowsi University of Mashhad, Mashhad, Iran, 2014.

[7] Z. Wang i A. C. Bovik, *Modern image quality assessment*. Synthesis Lectures on Image, Video & Multimedia Processing, Morgan & Claypool Publishers, 2006.

[8] H. R. Sheikh, A. C. Bovik, i L. Cormack, "No-reference quality assessment using nature scene statistics: JPEG2000," *IEEE Trans. Image Processing*, vol. 14, str. 1918-1927, 2005.

[9] L. Liang, S. Wang, J. Chen, S. Ma, D. Zhao, i W. Gao, "No-reference perceptual image quality metric using gradient profiles for JPEG2000," *Signal Processing: Image Communication*, vol. 25, str. 502-516, 2010.

[10] T. Brando i M. P. Queluz, "No-reference image quality assessment based on DCT domain statistics," *Signal Processing*, vol. 88, str. 822-833, 2008.

[11] A. Rehman i Z. Wang, "Reduced-reference image quality assessment by structural similarity estimation," *IEEE Trans. Image Processing*, vol. 21, str. 3378-3389, 2012.

[12] Z. Wang, E. P. Simoncelli, i A. C. Bovik, "Multi-scale structural similarity for image quality assessment," predstavljen na IEEE Asilomar Conf. on Signals, Systems, i Computers, 2003.

[13] Z. Wang, A. C. Bovik, i E. P. Simoncelli, "Image quality assessment: from error visibility to structural similarity," *IEEE Trans. Image Processing*, vol. 13, str. 600-612, 2004.

[14] H. R. Sheikh i A. C. Bovik, "Image information and visual quality," *IEEE Trans. Image Processing*, vol. 15, str. 430-444, 2006.

[15] E. C. Larson i D. M. Chandler,"Most apparent distortion: full-reference image quality assessment and the role of strategy,"*J. Electron. Imag.*, vol. 19, str. 011006:1-011006:21, 45. 2010.

[16] L. Zhang, L. Zhang, X. Mou, i D. Zhang, "FSIM: A feature similarity index for image quality assessment," *IEEE Trans. Image Processing*, vol. 20, str. 2378-2386, 2011.

[17] M.Vranješ, S. Rimac-Drlje i K. Grgić. "Review of objective video quality metrics and performance comparision using different databases", Signal Processing: Image Communication , Vol. 28, No.1, str. 1-19. 2013.

[18] Z. Wang i Q. Li, "Information content weighting for perceptual image quality assessment," *IEEE Trans. Image Process.*, Vol. 20, No. 5, str. 1185–1198, 2011.

[19] L. Zhang, D. Zhang, X. Mou, i D. Zhang, "FSIM: A feature similarity index for image quality assessment," *IEEE Trans. Image Process.*, Vol. 20, No. 8, str. 2378–2386, 2011.

[20] A. Liu, W. Lin, i M. Narwaria, "Image quality assessment based on gradient similarity," *IEEE Trans. Image Process.*, Vol. 21, No. 4, str. 1500–1512, 2012.

[21] L.Zhang, Y. Shen i H. Li, "VSI: A Visual Sailency-Induced Indeks fot Perceptual Image Quality Assessment ", IEEE Transactions on image processing, vol. 23, No. 10, 2014. str.4270-4281

[22] L. Itti, C. Koch, i E. Niebur, "A model of saliency-based visual attention for rapid scene analysis," *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol. 20, No. 11, str. 1254–1259, 1998.

[23] C. Koch i S. Ullman, "Shifts in selective visual attention: Towards the underlying neural circuitry," *Human Neurobiol.*, Vol. 4, No. 4, str. 219–227, 1985.

[24] L. Itti i P. Baldi, "Bayesian surprise attracts human attention," *Vis. Res.*, Vol. 49, No. 10, str. 1295–1306, 2009.

[25] E. C. L. Vu i D. M. Chandler, “Visual fixation patterns when judging image quality: Effects of distortion type, amount, and subject experience,” u *Proc. IEEE Southwest Symp. Image Anal. Interpretation*, , str. 73–76, 2008.

[26] E. C. Larson i D. M. Chandler, “Unveiling relationships between regions of interest and image fidelity metrics,” *Proc. SPIE, Vis. Commun. Image Process.*, Vol. 6822, str. 68222A:1–68222A:16, 2008.

[27] U. Engelke i H.-J. Zepernick, “Framework for optimal region of interest-based quality assessment in wireless imaging,” *J. Electron. Imag.*, Vol. 19, No. 1, str. 011005-1–011005-13, 2010.

[28] N. Ponomarenko *i drugi.*, “Color image database TID2013: Peculiarities and preliminary results,” u *Proc. 4th Eur. Workshop Vis. Inf. Process.*, str. 106–111, 2013.

[29] J. Harel, C. Koch, i P. Perona, “Graph-based visual saliency,” in *Advances in Neural Information Processing Systems*, Vol. 19. Cambridge, MA, USA: MIT Press, str. 545–552, 2007.

[30] M. Sonka, V. Hlavac, i R. Boyle, *Image Processing, Analysis, and Machine Vision*. Stanford, CT, USA: Cengage Learning, 2008.

[31] B. Jähne, H. Haubecker, i P. Geibler, *Handbook of Computer Vision and Applications*. New York, NY, USA: Academic, 1999.

[32] J.-M. Geusebroek, R. Van den Boomgaard, A. W. M. Smeulders, i H. Geerts, “Color invariance,” *IEEE Trans. Pattern Anal. Mach. Intell.*, Vol. 23, No. 12, str. 1338–1350, 2001.

[33] J.-M. Geusebroek, R. Van den Boomgaard, A. W. M. Smeulders, i A. Dev, “Color and scale: The spatial structure of color images,” u *Proc. Eur. Conf. Comput. Vis.*, str. 331–341, 2000.

[34] A.Zaric, N.Tatalovic, N.Brajkovic, H.Hlevnjak, M.Loncaric, E.Dumic, S.Grgic, "VCL@FER Image Quality Assessment Database", AUTOMATIKA Vol. 53, No. 4, str. 344–354, 2012.

[35] ITU-R Recommendation BT.500-11, "Methodology for the subjective assessment of the quality of television pictures," ITU, Geneva, Švicarska, 2002.

[36] VSI izvorni kod: http://sse.tongji.edu.cn/linzhang/IQA/VSI/VSI.htm

[37] SSIM m-datoteka: https://www.mathworks.com/matlabcentral/fileexchange/44971/image-denoising-using-modified-perona-malik-model-based-on-directional-laplacian/content/ssim.m

[38] PSNR m-datoteka: https://www.mathworks.com/matlabcentral/fileexchange/37326-psnr--image-processing-

SAŽETAK

Kako su subjektivne metode skup i dugotrajan proces za ocjenjivanje kvalitete slike koji se ne može provesti u stvarnom vremenu, koriste se objektivne metode od kojih su najpoznatije PSNR (engl. *Peak Signal to Noise Ratio*) i SSIM (engl. *Structural similarity index*). Posljednjih nekoliko godina provedena su mnoga istraživanja kako bi se došlo do zaključka koji dijelovi slika privlače najviše pažnju ljudskog vizualnog sustava. U ovom je radu predstavljena objektna metrika imena VSI (engl. *Visual saliency-based index*), koja koristi informacije tih istraživanja. Provedeni su eksperimenti ocjene kvalitete dijela slika iz VCL@FER baze slika, te su ti rezultati uspoređivani s rezultatima PSNR i SSIM metrika. Iako je za odabrane slike VSI pokazala slabije performanse od SSIM metrike, za puno veće skupove podataka VSI se ipak pokazala kao puno bolja metrika u predviđanju stvarne kvalitete slike.

Ključne riječi: kvaliteta slike, VSI , PSNR, SSIM, Pearsonov linearni koeficijent korelacije

ABSTRACT: VSI METRIC FOR OBJECTIVE IMAGE QUALITY EVALUATION

Subjective methods are expensive and time-consuming process for evaluation image quality and cannot be implemented in real time systems. That's why objective methods most notably Peak Signal to Noise Ratio (PSNR) and Structural similarity index (SSIM) are being used. Over the last few years many studies have been conducted in order to obtain the conclusion which image sections attract the most attention of the human visual system. This paper presents the objective metric name Visual sailency-based index (VSI), which uses information obtained from these studies. Image quality evaluation experiments were performed on set of images from VCL @ FER database and these results were compared to the results of PSNR and SSIM metrics. Although for selected images VSI showed weaker performance than SSIM, VSI proved to be a much better metric to predict the actual image quality for much larger data sets.

Keywords: image quality, VSI, PSNR, SSIM, Pearson's linear correlation coefficient

ŽIVOTOPIS

Marko Čanađija, rođen je 04. siječnja 1995. godine u Bjelovaru. Školovanje je započeo 2001. godine u III. osnovnoj školi također u Bjelovaru. Godine 2009. upisuje srednju tehničku školu u Bjelovaru, tijekom srednjoškolskog obrazovanja sudjeluje na natjecanju iz „Osnova elektrotehnike“ , Srednju školu uspješno završava 2013. godine.. Iste godine upisuje preddiplomski studij elektrotehnike na Elektrotehničkom fakultetu pri Sveučilištu J. J. Strossmayera u Osijeku, tijekom kojeg je sudjelovao u natjecanju iz „Elektronike 1“ održanog na Elektrijadi 2016. godine u Italiji.

Marko Čanađija

_____