Subjektivne i objektivne metode ocjene kvalitete mirne slike

Grčić, Goran

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:200:681310

Rights / Prava: In copyright / Zaštićeno autorskim pravom.

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

Repository / Repozitorij:

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

zir.nsk.hr

Image not found or type unknown

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU

ELEKTROTEHNIČKI FAKULTET

Stručni studij

SUBJEKTIVNE I OBJEKTIVNE METODE OCJENE KVALITETE MIRNE SLIKE

Završni rad

Goran Grčić

Osijek, 2016.

Sveučilište Josipa Jurja Strossmayera u Osijeku

ELEKTROTEHNIČKI FAKULTET OSIJEK

Obrazac Z1S: Obrazac za imenovanje Povjerenstva za obranu završnog rada na preddiplomskom stručnom studiju

Osijek, 06.07.2016.

Odboru za završne i diplomske ispite

Imenovanje Povjerenstva za obranu završnog rada na preddiplomskom stručnom studiju

Ime i prezime studenta:	Goran Grčić
Studij, smjer:	Preddiplomski stručni studij Elektrotehnika, smjer Informatika
Mat. br. studenta, godina upisa:	A 4131, 09.10.2015.
Mentor:	Doc.dr.sc. Mario Vranješ
Sumentor:	
Predsjednik Povjerenstva:	Doc.dr.sc. Marijan Herceg
Član Povjerenstva:	Denis Vranješ
Naslov završnog rada:	Subjektivne i objektivne metode ocjene kvalitete mirne slike
Znanstvena grana rada:	**Telekomunikacije i informatika (zn. polje elektrotehnika)**
Zadatak završnog rada	Kvalitetu mirne slike moguće je ocjenjivati subjektivnim metodama (gledatelji su izvor ocjene kvalitete) i objektivnim metodama (računalni algoritam je izvor ocjene kvalitete). U radu je potrebno odabrati 5 originalnih (neizobličenih) slika različitog sadržaja te ih pohraniti u različitim formatima za pohranu digitalne slike, čime se želi postići različita vizualna kvaliteta pohranjenih slika. Nakon toga treba ocijeniti kvalitetu izobličenih slika objektivnim metodama (PSNR i SSIM) i usporediti ju s rezultatima kvalitete istih slika dobivenima od strane 5 različitih gledatelja.
Prijedlog ocjene pismenog dijela ispita (završnog rada):	Vrlo dobar (4)
Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:	Primjena znanja stečenih na fakultetu: 2 Postignuti rezultati u odnosu na složenost zadatka: 2 Jasnoća pismenog izražavanja: 2 Razina samostalnosti: 2
Datum prijedloga ocjene mentora:	06.07.2016.

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

ETFOS
ELEKTROTEHNIČKI FAKULTET OSIJEK
Sveučilište Josipa Jurja Strossmayera u Osijeku

IZJAVA O ORIGINALNOSTI RADA

Osijek,
2016.

Ime i prezime studenta:	GORAN GRČIĆ
Studij :	PREDDIPLOMSKI STRUČNI STUDIJ, SMJER INFORMATIKA
Mat. br. studenta, godina upisa:	A4131, 2011.

Ovom izjavom izjavljujem da je rad pod nazivom**:**

SUBJEKTIVNE I OBJEKTIVNE METODE OCJENE KVALITETE MIRNE SLIKE

izrađen pod vodstvom mentora doc.dr.sc. MARIJA VRANJEŠA

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

2. OCJENA KVALITETE MIRNE SLIKE 2

2.1 Subjektivne metode za ocjenu kvalitete mirne slike 2

2.1.1 Jedno-podražajne metode 2

2.1.2 Dvo-podražajne metode 3

2.1.3 Poredbene metode 5

2.1.4 Proračun ukupne subjektivne ocjene kvalitete slike 6

2.2 Objektivne metode za ocjenu kvalitete mirne slike 7

2.2.1 Vršni odnos signal-šum 7

2.2.2 Indeks strukturalne sličnosti 8

2.2.3 Više-razinski indeks strukturalne sličnosti 9

2.2.4 Mjere vizualnih informacija 9

2.2.5 Vizualni odnos signal-šum 9

2.2.6 Ostale metode 10

3. BAZA MIRNIH SLIKA ZA OCJENU KVALITETE 11

4. OCJENA KVALITETE SLIKA IZ STVORENE BAZE 19

4.1 Subjektivna ocjena komprimiranih slika 19

4.2 Objektivna ocjena komprimiranih slika 21

4.3 Usporedba subjektivnih i objektivnih ocjena kvalitete komprimiranih slika 22

5. ZAKLJUČAK 26

LITERATURA 27

SAŽETAK 28

ABSTRACT 29

ŽIVOTOPIS 30

1. UVOD

Napretkom tehnologije sve se više koriste digitalne slike za međusobnu komunikaciju i kao izvor informacija. Pametni telefoni su već dobrim dijelom zamijenili fotoaparate i zbog toga je važna ocjena kvalitete slike. Za ocjenu kvalitete slike koriste se subjektivne i objektivne metode. Kod subjektivne metode ocjenu daju promatrači, a kod objektivne metode ocjenu daje računalo pomoću određenih algoritama. Subjektivne metode dijele se na jedno-podražajne (engl. *Single-Stimulus*) metode i dvo-podražajne (engl. *Double-Stimulus*) metode, a najpoznatije objektivne metode su vršni odnos signal-šum (engl. *Peak Signal to Noise Ratio* – PSNR), indeks strukturalne sličnosti (engl. *Structural Similarity Index* – SSIM), više-razinski indeks strukturalne sličnosti (engl. *Multiscale* SSIM – MSSIM), mjera vizualnih informacija (engl. *Visual Information Scale* – VIF) i vizualni odnos signal-šum (engl. *Visual Signal to Noise Ratio* – VSNR). Cilj svake objektivne metode je brzo i precizno dati konačan rezultat kvalitete slike i što veća sličnost sa subjektivnom ocjenom. U ovom je radu pet originalnih slika komprimirano različitim algoritmima kompresije kako bi se primijenile navedene metode i usporedili dobiveni rezultati ocjene kvalitete.

Ocjena kvalitete mirne slike detaljnije je obrađena u drugom poglavlju unutar kojeg su opisane subjektivne i objektivne metode. Treće poglavlje opisuje bazu mirnih slika za ocjenu kvalitete. U istom je poglavlju opisano kako su komprimirane originalne slike u programskom paketu *Matlab*. Ocjena kvalitete slika iz stvorene baze opisana je u četvrtom poglavlju. Ocjenjivanje je provedeno s pet ocjenjivača, a rezultati subjektivne metode, kao i rezultati objektivnih metoda prikazani su u tablicama. Na samom kraju poglavlja nalazi se usporedba subjektivnih i objektivnih ocjena kvalitete. Posljednje, peto poglavlje, donosi najbitnije zaključke.

1.1 Zadatak završnog rada

Kvalitetu mirne slike moguće je ocjenjivati subjektivnim metodama (gledatelji su izvor ocjene kvalitete) i objektivnim metodama (računalni algoritam je izvor ocjene kvalitete). U radu je potrebno odabrati 5 originalnih (neizobličenih) slika različitog sadržaja te ih pohraniti u različitim formatima za pohranu digitalne slike, čime se želi postići različita vizualna kvaliteta pohranjenih slika. Nakon toga treba ocijeniti kvalitetu izobličenih slika objektivnim metodama (PSNR i SSIM) i usporediti ju s rezultatima kvalitete istih slika dobivenima od strane 5 različitih gledatelja.

2. OCJENA KVALITETE MIRNE SLIKE

U današnje vrijeme, razvojem tehnologije, koristi se sve više aplikacija i uređaja za pohranu i razmjenu slika u svrhu komunikacije i raznih informacija. Zbog svakodnevne upotrebe potrebno je ocjenjivati kvalitetu slike. Postoje dva tipa metoda za ocjenu kvalitete slike:

1. Subjektivne metode - čovjek ocjenjuje kvalitetu slike;
2. Objektivne metode - računalo ocjenjuje kvalitetu slike.

2.1 Subjektivne metode za ocjenu kvalitete mirne slike

Subjektivni postupci se oslanjaju na ljudski vizualni sustav[1]. Pojedinac, odnosno, grupa ljudi ocjenjuje kvalitetu vizualnog sadržaja u unaprijed propisanim uvjetima, a ukupna ocjena kvalitete ispitanog sadržaja jednaka je prosjeku ocjena svih ispitanika. Subjektivni postupci se temelje na vizualnom dojmu pojedinca pa se može smatrati da subjektivni postupci rezultiraju stvarnom ocjenom kvalitete promatranog sadržaja. Ipak, treba napomenuti da dobiveni rezultati ovise o:

- psihičkom i emocionalnom stanju promatrača;
- uređaju za prikazivanje;
- svjetlosnim uvjetima.

Osim toga, subjektivni eksperimenti su ograničeni vremenom, skupi (puno promatrača) i ne mogu se ukomponirati u stvarno vrijeme aplikacije kao što je kompresija slike.

Subjektivne metode dijele se u tri kategorije[1]:

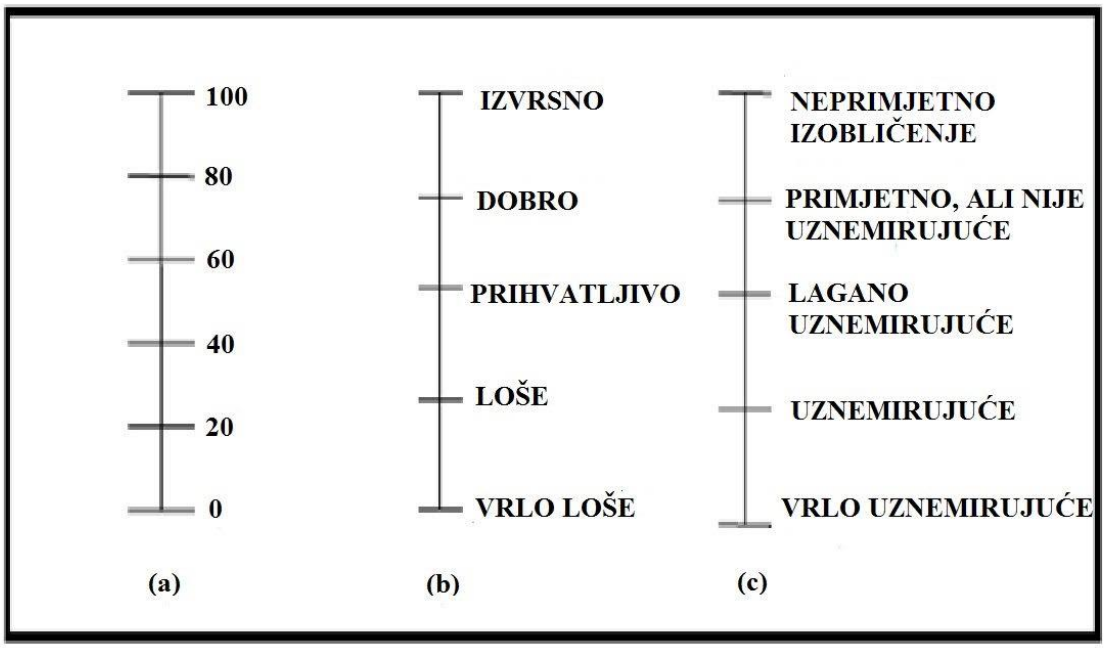
1. Jedno-podražajne metode
2. Dvo-podražajne metode
3. Poredbene metode

2.1.1 Jedno-podražajne metode

Kod jedno-podražajnih metoda, kao ispitni materijal prikazuje se više slika koje promatrač ocjenjuje bez da je bio u susretu s originalnom slikom. Postoje dva pristupa: bez ponavljanja ili s višestrukim ponavljanjem ispitnog materijala.

Koriste se dvije metode:

1. Jedno-podražajna ocjena kvalitete s kontinuiranom skalom (engl. *Single Stimulus Continuous Quality Scale*) – postupak s ocjenom kvalitete slike.
   Koristi se kontinuirana skala opsega 0-100.
2. Jedno-podražajna ocjena kvalitete sa skalom izobličenja (engl. *Single Stimulus Impairment Scale*) – postupak s ocjenom izobličenja slike.
   Tijekom ocjenjivanja promatrači slikama dodjeljuju ocjenu kvalitete ili ocjenu izobličenja. Na slici 2.1 prikazane su tri različite skale za jedno-podražajne metode prema preporuci međunarodne telekomunikacijske unije (engl. *Internacional Telecommunication Union* – ITU-R).



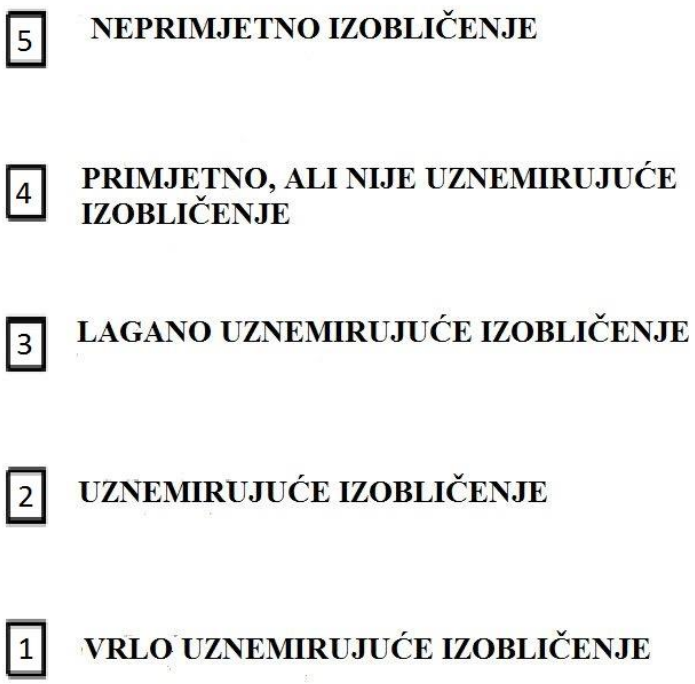
Slika 2.1. ITU-R (a) kontinuirana skala (b) skala kvalitete (c) skala izobličenja za jedno-podražajne metode [2]

2.1.2 Dvo-podražajne metode

Kod dvo-podražajnih metoda pred promatrača se postavlja i originalna slika i slika umanjene kvalitete, a promatrač ni u jednom trenutku ne zna koja slike je originalna, a koja izmijenjena.

1. Dvo-podražajna ocjena kvalitete sa skalom izobličenja (engl. *Double Stimulus Impairment Scale*) – postupak s ocjenom izobličenja slike.

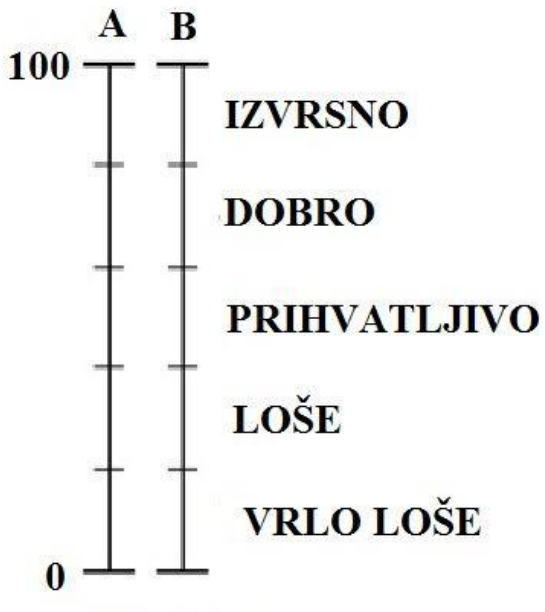
   Na samom početku promatranja ispitaniku se prvo prikaže referentna slika, a potom slike istog sadržaja, ali umanjene kvalitete. Slika umanjene kvalitete se prikazuje na istom zaslonu kao i referentna slika. Nakon promatranja obje slike promatrač daje ocjenu o stupnju izobličenja slike umanjene kvalitete u odnosu na referentnu sliku. Ocjene koje promatrači daju mogu biti od jedan do pet. Jedan znači potpuno izobličenje, dok pet znači minimalno izobličenje slike. Jedan par slika čine referentna slika i slika umanjene kvalitete istog sadržaja. Ispitivanje se temelji na promatranju niza parova slika s različitim stupnjem izobličenja, a jedan krug ispitivanja ne smije trajati duže od 30 minuta [3]. Na slici 2.2 dana je skala za ocjenu izobličenja za dvo-podražajnu metodu.



Slika 2.2 Skala za ocjenjivanje izobličenja za dvo-podražajnu metodu [2]

2. Dvo-podražajna ocjena kvalitete s kontinuiranom skalom *(*engl. *Double Stimulus Continuous Quality Scale)* – postupak s ocjenom kvalitete slike

   Postupak s ocjenom kvalitete slike započinje promatranjem parova slika istog sadržaja koji se prosljeđuju do monitora, na kome se obavlja promatranje. Cjelokupno promatranje parova slika jednog promatrača smije trajati najviše 30 minuta. Ispitanik ocjenjuje kvalitetu referentnih slika i slika s umanjenom kvalitetom. Slike unutar pojedinog para prikazuju se slučajnim redoslijedom. Zbog ovakvog načina prikazivanja promatrač ne zna koja slika je referentna, a koja izobličena [3]. Na slici 2.3 prikazana je skala za ocjenu kvalitete za dvo-podražajnu metodu.



Slika 2.3 Skala za ocjenjivanje kvalitete za dvo-podražajnu metodu [2]

2.1.3 Poredbene metode

Kod poredbenih metoda, promatrači daju ocjenu odnosa dviju slika. Za ocjenjivanje se koristi skala uspoređivanja. Na slici 2.4 prikaza je skala za uspoređivanje za poredbenu metodu.



Slika 2.4 Skala za uspoređivanje dvije slike kod poredbene metode [2]

2.1.4 Proračun ukupne subjektivne ocjene kvalitete slike

Srednja vrijednost ocjene za sve kombinacije naziva se srednja iskustvena vrijednost – MOS (engl. *Mean Opinion Score*). MOS se za jedno-podražajnu metodu za ocjenu izobličenja i dvo-podražajne metode (čije skale idu od nula do pet) računa prema formuli

$$MOS = \sum_{i=1}^{5} i \cdot p(i) \tag{2-1}$$

Za jedno-podražajnu metodu za ocjenu kvalitete (čija skala ide od nula do sto) MOS se računa prema formuli

$$MOS = \sum_{i=1}^{100} i \cdot p(i) \tag{2-2}$$

MOS se za poredbenu metodu (čija skala ide od -3 do 3) računa prema formuli

$$MOS = \sum_{i=-3}^{3} i \cdot p(i) \tag{2-3}$$

gdje je *p(i)* udio ocjene *i* u ukupnom broju ocjena.

2.2 Objektivne metode za ocjenu kvalitete mirne slike

Objektivne metode procjenjuju kvalitetu slike pomoću unaprijed određenih matematičkih formula, a čovjek ne utječe na krajnju ocjenu kvalitete. Zadatak objektivnih metoda je brzo i precizno dati konačni rezultat što sličniji onome od subjektivnih metoda.

S obzirom na zahtjeve za pristup referentnim slikama, objektivne metode dijele se na[1]:

1. *Full Reference* (FR)

   Mjeri se razlika između originalne slike i ispitne slike (koja je dobivena iz originala). Ocjena kvalitete ispitne slike mjeri se uz prisustvo originalne slike.

2. *Reduced Reference* (RR)

   Objektivna mjera temelji se na izdvajanju i usporedbi bitnih stavki originalnog i izobličenog sadržaja. Do ocjene kvalitete ispitnog sadržaja dolazi se usporedbom statističkih podataka dobivenih iz izdvojenih stavki originalnog i izobličenog sadržaja.

3. *No Reference* (NR)

   Mjeru se izobličenje ispitne slike bez uporabe originalne slike. Ocjena kvalitete ispitne slike temelji se na stavkama ispitne slike, bez prisustva originala [1].

U nastavku su opisane najčešće korištene objektivne metode za ocjenu kvalitete slike.

2.2.1 Vršni odnos signal-šum

Vršni odnos signal-šum (engl. *Peak Signal to Noise Ratio* – PSNR) daje ocjenu kvalitete slike, odnosno, uspoređuje ispitnu sliku s originalnom i daje stupanj izobličenja ispitne slike. Rezultat je PSNR vrijednost koja predstavlja logaritamski omjer najveće snage signala - jednake kvadratu maksimalne vrijednosti elemenata slike i snage šuma jednake srednjoj kvadratnoj pogrešci MSE (engl. *Mean Square Error*), između originalnog i izobličenog sadržaja. PSNR postupak je jednostavan i brz, međutim rezultati se ne podudaraju s rezultatima subjektivnih postupaka ocjene kvalitete jer PSNR zanemaruje svojstva ljudskog vizualnog sustava. Zbog toga PSNR nije idealno mjerilo ocjene kvalitete mirne slike.

PSNR se definira kao

$$PSNR_{dB} = 10\log_{10}\frac{(2^n - 1)^2}{MSE} \tag{2-4}$$

gdje je *n* broj bita korištenih za zapis elementa izvorne slike [1].
MSE se računa kao:

$$MSE = \frac{\sum_i \sum_j (a_{i,j} - b_{i,j})^2}{x \cdot y} \tag{2-5}$$

Gdje su $a_{i,j}$ i $b_{i,j}$ vrijednosti elemenata slike referentne i ispitivane slike na mjestu (*i,j*), a *x* i *y* visina i širina slike iskazane brojem elemenata slike.

2.2.2 Indeks strukturalne sličnosti

Indeks strukturalne sličnosti (engl. *Structural Similarity Index* – SSIM) je metoda koja računa sličnost dviju slika. Rezultat se dobije preko lokalnih prozora veličine (8x8). Tri vrijednosti koje se računaju za lokalne prozore su: sličnost svjetline, sličnost kontrasta i sličnost strukture. Te se vrijednosti povezuju u jedan SSIM indeks [3]. Mjerenjem izobličenja, promjene svjetline i kontrasta može se odrediti kvaliteta ispitnog sadržaja koja se izražava preko SSIM indeksa usporedbom originalne i izobličene slike.

Nakon proračuna parametara sličnosti svjetline (originalne i izobličene slike)

$$\mathrm{l(x,y)} = \frac{2\mu_x \mu_y + c_1}{\mu_x^2 + \mu_y^2 + c_1}, \tag{2-6}$$

sličnosti kontrasta

$$c(x,y) = \frac{2\sigma_x \sigma_y + c_1}{\sigma_x^2 \sigma_y^2 + c_2}, \tag{2-7}$$

i strukturalne sličnosti

$$s(x,y) = \frac{\sigma_{xy} + c_3}{\sigma_x \sigma_y + c_3}, \tag{2-8}$$

može se izračunati SSIM indeks koji može biti između nula i jedan. Nula znači da nema sličnosti, a jedan da su slike identične:

$$SSIM(x, y) = l(x, y) \cdot c(x, y) \cdot s(x, y), \tag{2-9}$$

gdje su μ_x, μ_y srednje vrijednosti lokalnih prozora x i y, σ_x, σ_y standardne devijacije originalnog i izobličenog signala, a σ_{xy} iznos kovarijance c_1,c_2,c_3 su konstante ubačene da bi se spriječilo dijeljenje s nulom [1].

2.2.3 Više-razinski indeks strukturalne sličnosti

Više-razinski indeks strukturalne sličnosti (engl. *Multiscale Structural Similarity Index* – MSSIM) metoda temelji se na SSIM metodi. Sličnost kontrasta i strukture se računaju na različitim frekvencijskim skalama dok se svjetlina računa na najnižoj frekvencijskoj skali. MSSIM je kombinacija izračunatih koeficijenata na svim skalama, a rezultat je između nula i jedan, gdje nula označava da nema sličnosti, a jedan da su slike identične [3].

2.2.4 Mjere vizualnih informacija

Mjera vizualnih informacija (engl. *Visual Information Scale*-VIF) uzima informaciju koja je zajednička originalnoj i izobličenoj slici u odnosu na informaciju koja se nalazi u samoj originalnoj slici. Ova metoda upotrebljava model prirodne scene NSS (engl. *Natural Scene Statistic*) zajedno s modelom izobličenja slike te modelom ljudskog vizualnog sustava. Rezultat može biti između nula i jedan, gdje nula znači da nema sličnosti, a jedan da su slike identične [3].

2.2.5 Vizualni odnos signal-šum

Vizualni odnos signal-šum (*Visual Signal to Noise Ratio* – VSNR) metoda računa izobličenje slike u dva koraka. Prvi korak upotrebljava *wavelet* model vizualnog maskiranja za određivanje izobličenja prirodne slike. Slika je savršena ukoliko je izobličenje ispod praga vidljivosti (VSNR = beskonačno). Međutim, ako je izobličenje iznad praga vidljivosti, onda drugi korak računa vizualna svojstva preko više skala: na nižim skalama svojstva kontrasta, na srednjim efekt boljeg uočavanja lokalnog maksimuma unutar slike. Rezultat VSNR metode je suma

udaljenosti navedenih svojstava. Što je veći VSNR znači da je slika sličnija originalnoj, odnosno, sadrži manje pogrešaka [3].

2.2.6 Ostale metode

Pored gore opisanih metoda postoji još mnogo objektivnih metoda za ocjenu kvalitete slike. Detaljnije o njima može se pronaći u [4].

3. BAZA MIRNIH SLIKA ZA OCJENU KVALITETE

U ovom poglavlju se opisuje kako je kreirana baza slika. Za kreiranje baze korišten je programski paket *Matlab*. Na samom početku rada odabrano je pet originalnih slika različitog sadržaja u BMP formatu rezolucije 640x480, s imenima: *priroda*, *guzva*, *grad*, *lice* i *t&j*. Originalne slike prikazane su na slici 3.1. Nakon toga pokreće se programski jezik *Matlab* i kreće se s kreiranjem baze. Za svaku od pet originalnih slika načinjeno je sedam komprimiranih slika: JPEG10, JPEG50, JPEG70, JPEG100, BMP, PNG i TIF. Broj uz JPEG predstavlja razinu kvalitete odabranu pri kompresiji.



a)



b)



c)



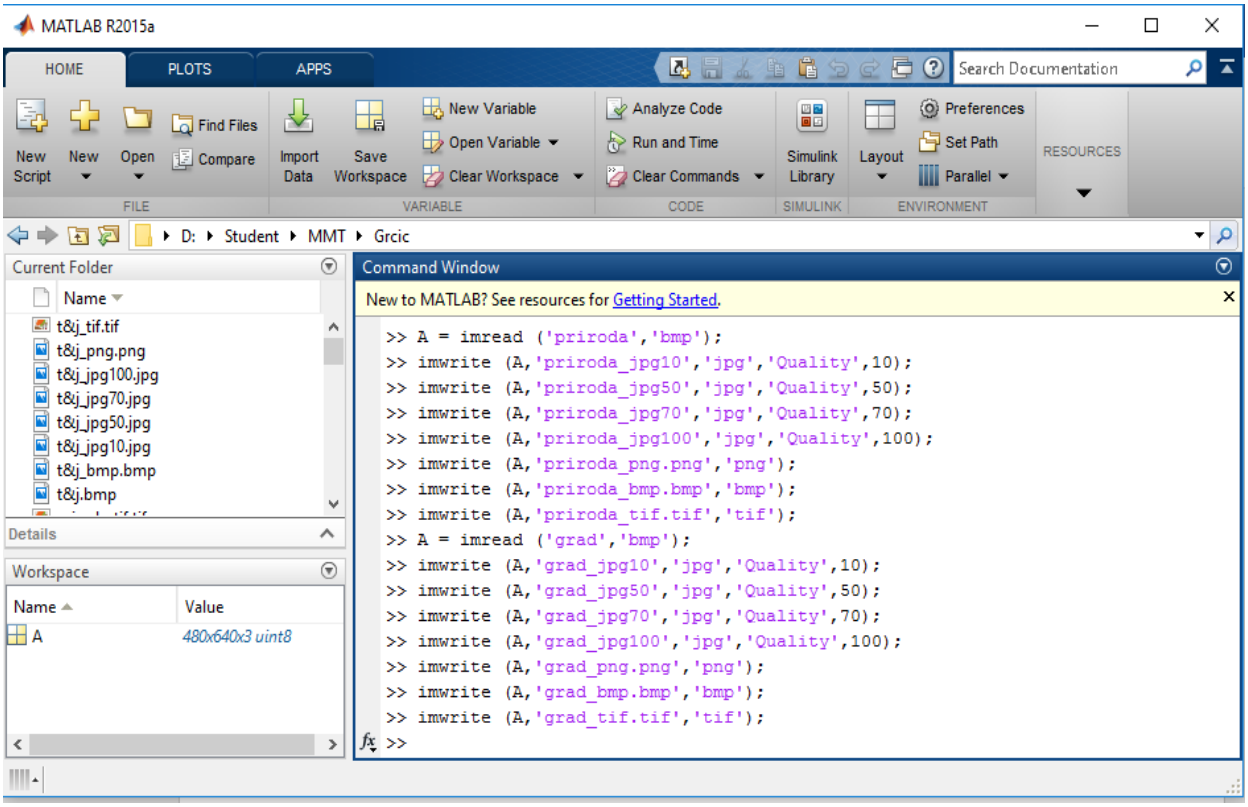
d)



e)

Slika 3.1 Originalne slike a) *priroda* b) *guzva* c) *grad* d) *lice* e) *t&j*

Na slici 3.2 prikazan je *Matlab* prozor s naredbama korištenim za kompresiju originalnih slika.



Slika 3.2 Glavni prozor u *Matlabu* i naredbe za pohranu originalnih slika u različitim formatima

Baza slika je kreirana pomoću naredbe za učitavanje slika – *imread* i naredbe za pohranu slika – *imwrite*. Slika *priroda* učitava se pomoću naredbe:

A = imread('priroda','bmp');

Na slikama 3.3-3.9 prikazani su primjeri dobivenih slika *prirode* uključenih u bazu.

Za pohranu slike u JPEG formatu uz razinu kvalitete 10 koristi se naredba:

imwrite (A,'priroda_jpg10.jpg','jpg','Quality',10);



Slika 3.3 Slika *priroda* u JPEG formatu uz razinu kvalitete 10

Za pohranu slike u JPEG formatu uz razinu kvalitete 50 koristi se naredba:

imwrite (A,'priroda_jpg50.jpg','jpg','Quality',50);



Slika 3.4 Slika *priroda* u JPEG formatu uz razinu kvalitete 50

Za pohranu slike u JPEG formatu uz razinu kvalitete 70 koristi se naredba:
imwrite (A,'priroda_jpg70.jpg','jpg','Quality',70);



Slika 3.5 Slika *priroda* u JPEG formatu uz razinu kvalitete 70

Za pohranu slike u JPEG formatu uz razinu kvalitete 100 koristi se naredba:
imwrite (A,'priroda_jpg100.jpg','jpg','Quality',100);



Slika 3.6 Slika *priroda* u JPEG formatu uz razinu kvalitete 100

Za pohranu slike u PNG formatu koristi se naredba:

imwrite (A,'priroda_png.png','png');



Slika 3.7 Slika *priroda* u PNG formatu

Za pohranu slike u TIFF formatu koristi se naredba:

imwrite (A,'priroda_tif.tif'','tif');



Slika 3.8 Slika *priroda* u TIFF formatu

Za pohranu slike u BMP formatu koristi se naredba:

imwrite (A,'priroda_bmp.bmp','bmp');



Slika 3.9 Slika *priroda* u BMP formatu

Isti postupak se ponavlja i za preostale četiri originalne slike. Izobličene slike dane su na CD-u priloženom uz ovaj rad.

Dobiveno je ukupno trideset i pet komprimiranih slika u različitim formatima, različite veličine datoteka. U tablici 3.1 prikazane su veličine datoteka pojedinih slika.

Tablica 3.1 Veličina slika u kB

Ime slike	Format	Veličina [kB]
grad	BMP	900,0
grad_bmp	BMP	900,0
grad_jpg10	JPEG	11,3
grad_jpg50	JPEG	30,7
grad_jpg70	JPEG	41,7
grad_jpg100	JPEG	240,0
grad_png	PNG	459,0
grad_tif	TIF	907,0
guzva	BMP	900,0
guzva_bmp	BMP	900,0

guzva_jpg10	JPEG	37,3
guzva_jpg50	JPEG	92,4
guzva_jpg70	JPEG	120,0
guzva_jpg100	JPEG	441,0
guzva_png	PNG	798,0
guzva_tif	TIF	907,0
lice	BMP	900,0
lice_bmp	BMP	900,0
lice_jpg10	JPEG	9,48
lice_jpg50	JPEG	24,9
lice_jpg70	JPEG	34,5
lice_jpg100	JPEG	210,0
lice_png	PNG	451,0
lice_tif	TIF	892,0
priroda	BMP	900,0
priroda_bmp	BMP	900,0
priroda_jpg10	JPEG	15,7
priroda_jpg50	JPEG	44,3
priroda_jpg70	JPEG	60,7
priroda_jpg100	JPEG	285,0
priroda_png	PNG	554,0
priroda_tif	TIF	902,0
t&j	BMP	900,0
t&j_bmp	BMP	900,0
t&j_jpg10	JPEG	10,3
t&j_jpg50	JPEG	24,8
t&j_jpg70	JPEG	33,7
t&j_jpg100	JPEG	167,0
t&j_png	PNG	342,0
t&j_tif	TIF	907,0

4. OCJENA KVALITETE SLIKA IZ STVORENE BAZE

U ovom poglavlju se ocjenjuje kvaliteta slika iz prethodno kreirane baze. U tablicama se prikazuju rezultati subjektivne i objektivne ocjene komprimiranih slika .

4.1 Subjektivna ocjena komprimiranih slika

Prije početka ocjenjivanja odabrano je pet originalnih slika različitog sadržaja čijom obradom, u programskom paketu *Matlab,* je nastalo trideset i pet komprimiranih slika. Slike su poredane nasumičnim redoslijedom te su im dodijeljeni brojevi od jedan do četrdeset, kao što je prikazano u tablici 4.1. Pet ispitanika davalo je svoje subjektivne ocjene od nula do sto (Sl.2.3) za svaku sliku posebno, redoslijedom prikazanim u tablici 4.1. Nakon završetka ispitivanja izračunata je srednja ocjena kvalitete svake slike (MOS).

Tablica 4.1 Subjektivna ocjena komprimiranih slika

Ime slike	Oznaka pri testiranju	MOS
priroda_png	1	53
lice_bmp	2	85
grad_jpg70	3	54
priroda	4	55
t&j_tif	5	39
grad_bmp	6	73
guzva	7	29
priroda_jpg50	8	40
lice_jpg100	9	87
grad_png	10	81
guzva_jpg70	11	29
priroda_tif	12	49
t&j_bmp	13	47
guzva_jpg10	14	11
lice_jpg50	15	59
t&j_70	16	45

guzva_tif	17	47
priroda_bmp	18	66
lice	19	90
grad_jpg50	20	54
t&j_jpg100	21	50
lice_jpg70	22	68
priroda_jpg70	23	52
grad_tif	24	84
guzva_png	25	38
grad_jpg10	26	13
t&j	27	47
lice_png	28	79
grad	29	78
priroda_jpg100	30	62
t&j_jpg10	31	17
guzva_jpg50	32	35
lice_jpg10	33	14
guzva_bmp	34	40
priroda_jpg10	35	8
t&j_png	36	64
guzva_jpg100	37	49
lice_tif	38	88
t&j_jpg50	39	52
grad_jpg100	40	82

Pri samom ocjenjivanju gledatelji su ocjenjivali i kvalitetu originalnih slika, bez da su to znali.

4.2 Objektivna ocjena komprimiranih slika

Objektivna ocjena kvalitete komprimiranih slika dobila se pomoću alata *MSU Video Quality Tool*[5] tako što su uspoređene komprimirana slika i originalna slika. Ocjenjivanje je vršeno pomoću dviju metoda, a to su PSNR i SSIM . Rezultati objektivnih ocjena prikazani su u tablici 4.2.

Tablica 4.2 Objektivna ocjena komprimiranih slika

Ime slike	PSNR	SSIM
priroda_png	100	1
lice_bmp	100	1
grad_jpg70	36	0,95
priroda	100	1
t&j_tif	100	1
grad_bmp	100	1
guzva	100	1
priroda_jpg50	33	0,93
lice_jpg100	46	0,995
grad_png	100	1
guzva_jpg70	32	0,98
priroda_tif	100	1
t&j_bmp	100	1
guzva_jpg10	22	0,88
lice_jpg50	36	0,94
t&j_70	43	0,98
guzva_tif	100	1
priroda_bmp	100	1
lice	100	1
grad_jpg50	34	0,93
t&j_jpg100	46	0,995
lice_jpg70	38	0,96
priroda_jpg70	35	0,96

grad_tif	100	1
guzva_png	100	1
grad_jpg10	29	0,82
t&j	100	1
lice_png	100	1
grad	100	1
priroda_jpg100	44	0,995
t&j_jpg10	33	0,90
guzva_jpg50	29	0,97
lice_jpg10	31	0,83
guzva_bmp	100	1
priroda_jpg10	28	0,80
t&j_png	100	1
guzva_jpg100	38	0,997
lice_tif	100	1
t&j_jpg50	41	0,97
grad_jpg100	44	0,99

4.3 Usporedba subjektivnih i objektivnih ocjena kvalitete komprimiranih slika

Krajnji cilj rada bio je usporediti rezultate objektivnih metoda s rezultatima subjektivnih eksperimenata. U tablici 4.3 prikazani su zajedno subjektivni i objektivni rezultati za sve slike testirane u eksperimentima.

Tablica 4.3 Usporedba subjektivne i objektivne ocjene kvalitete komprimirane slike

Ime slike	Format	Veličina [kB]	MOS	PSNR	SSIM
grad	BMP	900	78	100	1
grad_bmp	BMP	900	73	100	1
grad_jpg10	JPEG	11,3	13	29	0,82
grad_jpg50	JPEG	30,7	54	34	0,93
grad_jpg70	JPEG	41,7	54	36	0,95
grad_jpg100	JPEG	240	82	44	0,99
grad_png	PNG	459	81	100	1
grad_tif	TIF	907	84	100	1
guzva	BMP	900	29	100	1
guzva_bmp	BMP	900	40	100	1
guzva_jpg10	JPEG	37,3	11	22	0,88
guzva_jpg50	JPEG	92,4	35	29	0,97
guzva_jpg70	JPEG	120	29	32	0,98
guzva_jpg100	JPEG	441	49	38	0,997
guzva_png	PNG	798	38	100	1
guzva_tif	TIF	907	47	100	1
lice	BMP	900	90	100	1
lice_bmp	BMP	900	85	100	1
lice_jpg10	JPEG	9,48	14	31	0,80
lice_jpg50	JPEG	24,9	59	36	0,94
lice_jpg70	JPEG	34,5	68	38	0,96
lice_jpg100	JPEG	210	87	46	0,995
lice_png	PNG	451	79	100	1
lice_tif	TIF	892	88	100	1
priroda	BMP	900	55	100	1
priroda_bmp	BMP	900	66	100	1
priroda_jpg10	JPEG	15,7	8	28	0,90
priroda_jpg50	JPEG	44,3	40	33	0,93
priroda_jpg70	JPEG	60,7	52	35	0,96
priroda_jpg100	JPEG	285	62	44	0,995

priroda_png	PNG	554	53	100	1
priroda_tif	TIF	902	49	100	1
t&j	BMP	900	47	100	1
t&j_bmp	BMP	900	47	100	1
t&j_jpg10	JPEG	10,3	17	33	0,90
t&j_jpg50	JPEG	24,8	52	41	0,97
t&j_jpg70	JPEG	33,7	45	43	0,98
t&j_jpg100	JPEG	167	50	46	0,995
t&j_png	PNG	342	64	100	1
t&j_tif	TIF	907	39	100	1

Sličnost subjektivnih i objektivnih rezultata mjerena je pomoću apsolutne vrijednosti Pearsonovog linearnog koeficijenta korelacije, koji se računa kao:

$$|r| = \left| \frac{\sum_{i=1}^{n} (X_i - \bar{X}') \cdot (Y_i - \bar{Y}')}{\sqrt{\sum_{i=1}^{n} (X_i - \bar{X}')^2} \cdot \sqrt{\sum_{i=1}^{n} (Y_i - \bar{Y}')^2}} \right| \tag{4-1}$$

gdje je $\{X_i,\ldots X_n\}$ skup podataka subjektivne metrike, $\{Y_i,\ldots Y_n\}$ skup podataka objektivne metrike, n broj elemenata u pojedinom skupu podataka, $\bar{X}'$ i $\bar{Y}'$ srednja vrijednost odgovarajućeg skupa podataka. Pearsonov linearni koeficijent korelacije se kreće u rasponu od nula do jedan, budući da je računata njegova apsolutna vrijednost.

Pearsonov linearni koeficijent korelacije za ocjene iz tablice 4.3 za PSNR iznosi 0,4655, a za SSIM iznosi 0,6485.

Iz dobivenih rezultata se vidi da su rezultati SSIM metode sličniji subjektivnim rezultatima, a samim time i bolji od rezultata PSNR metode koja zanemaruje svojstva ljudskog vizualnog sustava. PSNR metoda uspoređuje ispitnu sliku s originalnom na bazi točka-točka, dok SSIM metoda računa sličnost svjetline, kontrasta i strukture, te samim time bolje oponaša neka svojstva ljudskog vizualnog sustava.

S obzirom na ocjene promatrača može se reći da je JPEG format najbolji ako se uzme u obzir ocjena kvalitete slike i količina memorije koju zauzima. Ocjene promatrača za različite formate su

dosta slične, ali JPEG format zauzima puno manje memorije od ostalih formata što je vidljivo kod slike *priroda* s kvalitetom 70 koja je dobila ocjenu 52 uz veličinu datoteke od 60,7 kB, dok je slika *priroda* u TIF formatu dobila ocjenu 49, a zauzima 902 kB memorije. Ovo je samo jedan od primjera. U tablici 4.3 može se vidjeti više takvih primjera.

5. ZAKLJUČAK

Glavni zadatak ovog završnog rada prvotno je bilo upoznavanje sa subjektivnim i objektivnim metodama za ocjenu kvalitete mirne slike. Subjektivne i objektivne metode za ocjenu kvalitete slike pomažu pri obradi slika. Kvaliteta slike jedan je od glavnih pokazatelja koliko uspješna je bila kompresija slike.

Prije samog ispitivanja stvorena je baza komprimiranih slika za provođenje subjektivne i objektivne ocjene kvalitete slika. Nakon njihove usporedbe može se zaključiti da su rezultati SSIM metode bolji od rezultata PSNR metode jer su sličniji rezultatima subjektivne metode. Međutim, i subjektivne i objektivne metode imaju svoje pozitivne i negativne strane. Subjektivne metode su realnije, ali za njihovu realizaciju potrebno je izdvojiti puno vremena te su skupe. Osim toga, rezultati ove metode ovise o dosta faktora kao što su psihičko i emocionalno stanje promatrača, svjetlosni uvjeti, uređaj za prikazivanje. Upravo zbog toga upotrebljavaju se objektivne metode koje su puno brže i jeftinije. Unatoč svemu, opći zaključak provedenog ispitivanja je da se još puno mora raditi na razvoju objektivnih metoda kako bi bile brze i rezultati što sličniji rezultatima subjektivnih metoda.

LITERATURA

[1] G. Gvozden „Uporaba značajki vizualnog sadržaja za objektivno vrednovanje kvalitete slike“, Fakultet elektrotehnike i računarstva Zagreb https://www.fer.unizg.hr/_download/repository/Goran_Gvozden,_KDI.pdf

[2] S. Maksimović-Moićević „Predlog nove mere za ocenu kvaliteta slike prilikom interpolacije i njena implementacija u računarskoj obradi signala slike“, doktorska disertacija, Fakultet tehničkih nauka odsek za računarsku tehniku i računarske komunikacije, Novi Sad, 2015. http://www.ftn.uns.ac.rs/n288484245/disertacija

[3] E. Dumić „Postupci za objektivnu ocjenu kvalitete slike“, Fakultet elektrotehnike i računarstva Zagreb https://www.fer.unizg.hr/_download/repository/Dumic,_KDI.pdf

[4] K.-H. Thung, Paramesran Raveendran „A Survey of Image Quality Measures“, International Conference for Technical Postgraduates, 2009, str. 1-4

[5] *MSU Video Quality Measurement Tool* http://compression.ru/video/quality_measure/vqmt_download_en.html#free

SAŽETAK

Subjektivna i objektivna ocjena kvalitete slike pomažu pri obradi slika. Kada se neka slika komprimira, subjektivne i objektivne metode pokazuju koliko je dobra kompresija slike jer ocjena pokazuje koliki utjecaj na kvalitetu je imala kompresija. U radu je prikazan postupak kompresije slike u programskom paketu *Matlab*. Provedeno je subjektivno ocjenjivanje kvalitete komprimiranih slika i objektivno ocjenjivanje (PSNR i SSIM) kvalitete komprimiranih slika. Cilj objektivne metode je imati rezultate što sličnije rezultatima subjektivne metode. Prikazana je usporedba rezultata subjektivnih i objektivnih metoda koja pokazuje da se rezultati niti jedne objektivne metode ne podudaraju sa subjektivnim rezultatima u potpunosti.

Ključne riječi: subjektivna metoda, objektivna metoda, kvaliteta slike, *Matlab*, PSNR, SSIM

SUBJECTIVE AND OBJECTIVE METHODS FOR IMAGE QUALITY EVALUATION

ABSTRACT

Subjective and objective assessment of image quality are helpful during image processing. When an image is compressed, subjective and objective methods show how compression has the big influence on image quality. In this work the process of image compression in Matlab program is shown, including the subjective quality assessment of compressed image and the objective quality assessment of image (PSNR, SSIM). The purpose of objective methods is to have results very similar to those of subjective methods. Comparison of subjective and objective methods is shown in this work. The results show none of the results of objective methods match with subjective methods.

Keywords: subjective method, objective method, image quality, Matlab, PSNR, SSIM

ŽIVOTOPIS

Goran Grčić je rođen 11. srpnja 1992. godine u Somboru. Pohađao je osnovnu školu „dr. Franjo Tuđman“ u Belom Manastiru. Za vrijeme osnovnoškolskog obrazovanja pohađao je natjecanja iz matematike na međužupanijskoj razini. 2007. godine upisuje Prvu srednju školu, također u Belom Manastiru, smjer tehničar za računalstvo. Drugi razred srednje škole završava u Tehničkoj školi u Virovitici, smjer elektrotehnika, gdje je boravio jer se aktivno bavio nogometom. Nakon povratka iz Virovitice, 2011. završava srednju školu u Belom Manastiru te iste godine upisuje Elektrotehnički fakultet u Osijeku.

_____

Goran Grčić