

<https://doi.org/10.37528/FTTE/9788673954752/POSTEL.2023.014>

PRIMENA PRAGA JEDVA UOČLJIVIH RAZLIKA U OBJEKTIVNOJ PROCENI KVALITETA JPEG KOMPRIMOVANIH SLIKA

Boban Bondžulić, Nenad Stojanović

Univerzitet odbrane u Beogradu – Vojna akademija

bondzulici@yahoo.com, nivzvk@hotmail.com

Rezime: *U radu je pokazano da se primenom praga jedva uočljivih razlika značajno mogu unaprediti performanse vršnog odnosa signal/šum u proceni kvaliteta JPEG komprimovanih slika. Prag je određen na globalnom nivou, odnosno na nivou kompletne slike, predikcijom vršnog odnosa signal/šum koji odgovara granici između kompresije bez gubitka i sa gubitkom vizuelnih informacija. U predikciji su korišćena jednostavna obeležja (prostorna frekvencija i prostorna informacija) izvedena iz originalne nekomprimovane slike i kriva zadovoljstva korisnika komprimovanim sadržajem dobijena primenom dubokog učenja. Unapređenje je ilustrovano kroz dijagrame rasipanja i kvantitativne pokazatelje za šest javno dostupnih baza slika sa rezultatima subjektivnih testova, gde jedna baza sadrži slike iz infracrvenog dela elektromagnetskog spektra. Stepen unapređenja zavisi od načina predikcije praga uočljivih razlika i korišćene baze slika, ali se primenom predikcije izvedene iz jednostavnih obeležja dobijaju nešto lošiji rezultati nego kada se koristi predikcija izvedena iz krive zadovoljstva korisnika.*

Ključne reči: *jedva uočljive razlike (JND), JPEG kompresija, objektivna procena kvaliteta, vršni odnos signal/šum (PSNR)*

1. Uvod

Tehnike kompresije slike bez gubitka vizuelnih informacija poslednjih godina dobijaju na značaju zahvaljujući javno dostupnim bazama slika sa rezultatima subjektivnih testova. Cilj ovih tehniki jeste da se dobije komprimovana slika sa najvećim stepenom kompresije tako da posmatrač ne može razlikovati original od njegove komprimovane verzije. Ove tehnike su od posebnog značaja u daljinskom osmatranju i medicini, gde očuvanje vizuelnih informacija ima veliki uticaj na pravilnu interpretaciju podataka. U odnosu na tehnike kompresije bez gubitka informacija ostvaruje se dodatni stepen kompresije od približno osam puta [1].

Za razvoj tehnika kompresije bez gubitka vizuelnih informacija bitno je razumevanje vizuelnog sistema čoveka (engl. *Human Visual System*, HVS), a jedna od njegovih bitnih karakteristika je prag jedva uočljivih razlika (engl. *Just Noticeable Difference*, JND). Prag se može određivati na nivou kompletne slike, što je predmet istraživanja u ovom radu, na nivou regiona slike i na nivou pojedinačnih piksela [2]. JND

koncept se odnosi na određivanje minimalne razlike (prag vidljivosti ili vizuelna redundansa) između dva vizuelna signala koju će posmatrač detektovati. Ova razlika predstavlja granicu između kompresije bez i sa gubitkom vizuelnih informacija i odgovara prvoj JND tački. Korišćenjem slike koja odgovara prvoj JND tački može se odrediti druga JND tačka, odnosno niže JND tačke se koriste za određivanje viših JND tačaka. Predikcija pozicije prve JND tačke može biti realizovana kroz predikciju ciljne vrednosti objektivnog kvaliteta ili kroz predikciju parametra kojim se kontroliše kompresija (faktor kvaliteta, parametar kvantizacije, broj bita po pikselu, stepen kompresije). Pouzdani pristupi iz [3, 4] za predikciju vršnog odnosa signal/šum (engl. *Peak Signal-to-Noise Ratio*, PSNR) prve JND tačke koriste amplitudu gradijenta izvorne nekomprimovane slike, dok pristupi koji koriste tehnike dubokog učenja daju nešto veću pouzdanost predikcije [5].

U ovom radu je na šest javno dostupnih baza koje sadrže slike sa JPEG kompresijom pokazano da se značajno mogu unaprediti performanse PSNR objektivne mere u proceni kvaliteta JPEG komprimovanih slika uzimanjem u obzir vrednosti PSNR prve JND tačke. Dodatno je pokazano da stepen unapređenja zavisi od pristupa koji se koristi za predikciju pozicije prve JND tačke.

Rad je organizovan na sledeći način. Nakon uvodnog dela, u drugom delu rada opisani su pristupi koji se koriste za predikciju pozicije prve JND tačke. U trećem delu rada predstavljen je način na koji se predikcije pozicije prve JND tačke koriste za definisanje objektivne mere procene kvaliteta JPEG komprimovanih slika. Dodatno su date i analizirane performanse novouvedene objektivne mere kroz kvantitativne pokazatelje i dijagrame rasipanja. U poslednjem delu rada sumirani su najvažniji rezultati i dati pravci budućeg rada.

2. Predikcija pozicije prve JND tačke

Na slici 1 je prikazana originalna (nekomprimovana) slika iz MCL-JCI baze [6] i njene četiri JPEG komprimovane verzije (desne polovine) koje odgovaraju JND tačkama. Komprimovane verzije su dobijene za faktore kvaliteta 54, 29, 16 i 11, a koji su dobijeni na osnovu rezultata subjektivnih testova. Sa slike se jasno mogu uočiti razlike između komprimovanih slika, ali se razlike između originala i komprimovane slike koja odgovara prvoj JND tački mnogo teže uočavaju. Razlike se uočavaju u uniformnim regionima slike, dok se u regionima bogatim teksturom razlike slabo uočavaju.

Jednostavnii pristupi za predikciju PSNR prve JND tačke (PSNR JND #1) iz [3, 4] koriste sliku u nijansama sive, a za konverziju slike u boji (RGB) dimenzija $N \times M$ u sivu sliku koriste standardnu konverziju:

$$F(n, m) = 0.299R(n, m) + 0.587G(n, m) + 0.114B(n, m), \quad (1)$$

gde su n i m prostorne koordinate ($n = 1, 2, \dots, N; m = 1, 2, \dots, M$). Nakon konverzije slike se snimaju u 64-bitni format, sa dinamičkim opsegom od 0 do 1. Oba pristupa za predikciju pozicije prve JND tačke koriste amplitudu gradijenta, pri čemu se u [3] koriste Sobel filterske maske:

$$\begin{aligned} g_x(n, m) &= F(n+1, m+1) + 2 \cdot F(n+1, m) + F(n+1, m-1) \\ &\quad - F(n-1, m-1) - 2 \cdot F(n-1, m) - F(n-1, m+1) \end{aligned}, \quad (2)$$

$$\begin{aligned} g_y(n, m) &= F(n-1, m+1) + 2 \cdot F(n, m+1) + F(n+1, m+1) \\ &\quad - F(n-1, m-1) - 2 \cdot F(n, m-1) - F(n+1, m-1) \end{aligned}, \quad (3)$$

$$SI(n, m) = \sqrt{g_x^2(n, m) + g_y^2(n, m)}, \quad (4)$$

dok se u [4] koriste razlike amplituda susednih piksela po redovima (RD) i kolonama (CD):

$$RD(n, m) = F(n, m) - F(n+1, m), \quad (5)$$

$$CD(n, m) = F(n, m) - F(n, m+1), \quad (6)$$

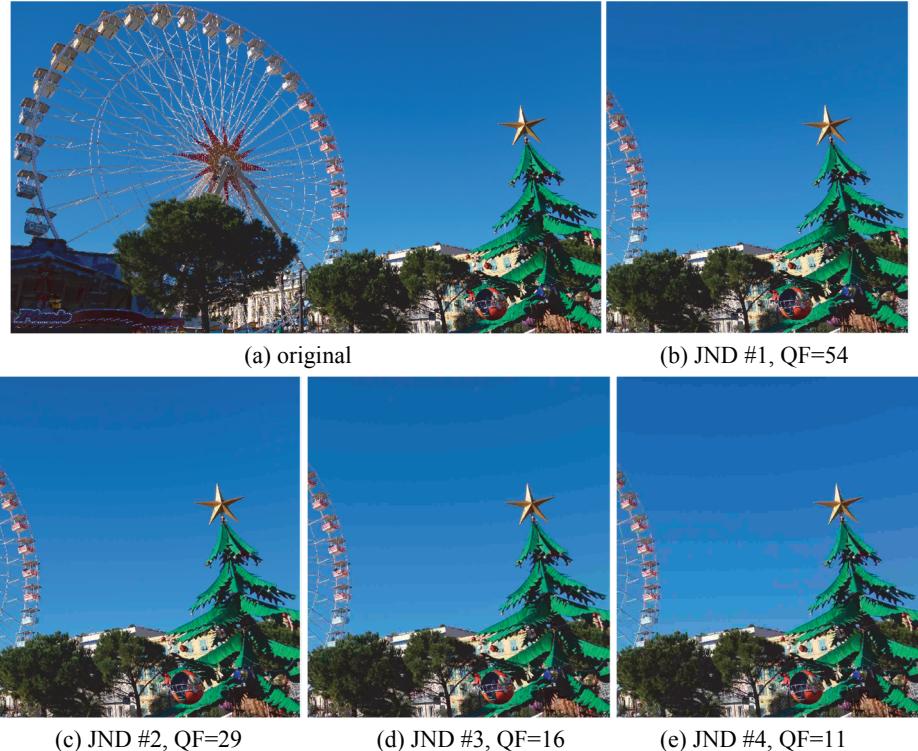
$$SF(n, m) = \sqrt{(RD(n, m))^2 + (CD(n, m))^2}. \quad (7)$$

Usrednjavanjem lokalnih vrednosti amplituda gradijenta se dobijaju obeležja slike poznata kao prostorna informacija (SI_{mean}) i prostorna frekvencija (SF_{mean}), a koja govore o kompleksnosti slike:

$$SI_{mean} = mean_{space}[SI]/g_{max}, \quad (8)$$

$$SF_{mean} = mean_{space}[SF]. \quad (9)$$

U prethodnim jednačinama sa g_{max} je označena eksperimentalno određena maksimalna vrednost amplituda gradijenta koja se dobija primenom Sobel maski za sive slike sa dinamičkim opsegom od 0 do 1 ($g_{max}=4.472$), dok je $mean_{space}$ oznaka za operaciju prostornog usrednjavanja.



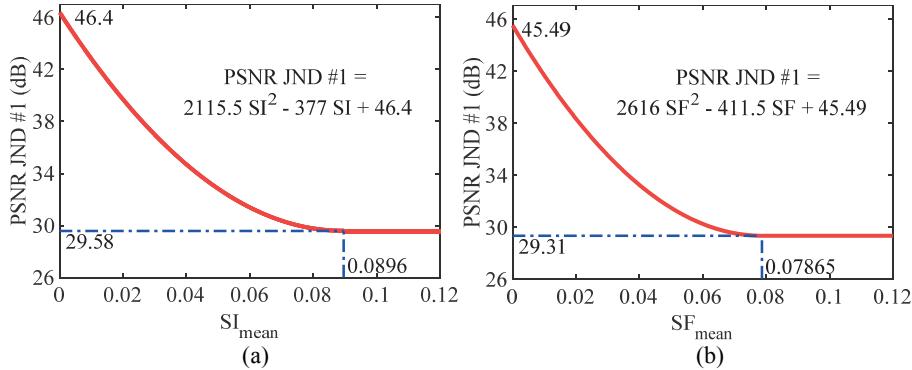
Slika 1. Originalna slika i njene četiri JPEG komprimovane verzije (desne polovine) koje odgovaraju pozicijama JND tačaka

Za predikciju PSNR JND #1 se u [3, 4] koriste zakoni preslikavanja drugog reda:

$$PSNR(SI) = \begin{cases} 2115.5 SI^2 - 377 SI + 46.4, & SI \leq 0.0896, \\ 29.58, & SI > 0.0896 \end{cases}, \quad (10)$$

$$PSNR(SF) = \begin{cases} 2616 SF^2 - 411.5 SF + 45.49, & SF \leq 0.07865, \\ 29.31, & SF > 0.07865 \end{cases}, \quad (11)$$

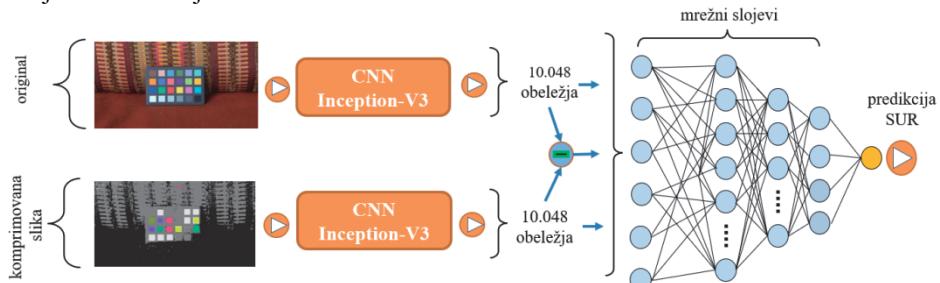
kod kojih su optimalne vrednosti parametara određene na osnovu rezultata subjektivnih testova MCL-JCI baze. Zakoni preslikavanja su prikazani na slici 2.



Slika 2. Predikcije vrednosti PSNR prve JND tačke na osnovu: (a) prostorne informacije i (b) prostorne frekvencije

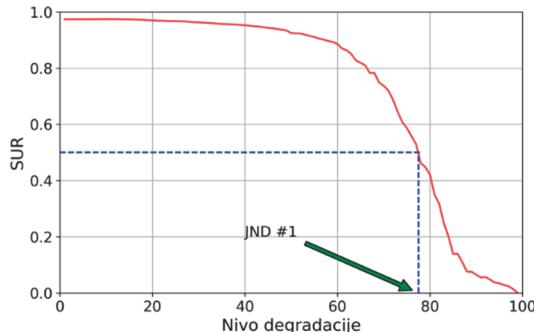
Sa slike 2 se može zaključiti da se sa povećanjem SI/SF vrednosti predikcija PSNR smanjuju do minima funkcije preslikavanja ($PSNR_{min}=29.58$ dB, odnosno $PSNR_{min}=29.31$ dB). Na ovaj način se kod slika koje sadrže regione neuniformnog sadržaja (veće SI/SF vrednosti) može tolerisati veći stepen degradacije nego kod regiona sa homogenim sadržajem (niže SI/SF vrednosti). Takođe, blokovskom JPEG kompresijom se potiskuju visokofrekvencijske komponente. U homogenim regionima sa postepenim promenama boje/intenziteta, blokovske efekte će posmatrači uočiti. Nasuprot tome, degradacije su manje uočljive u regionima bogatim teksturom.

Za predikciju pozicije prve JND tačke se u [5] koristi stepen zadovoljnih korisnika (engl. *Satisfied User Ratio*, SUR) komprimovanim sadržajem dobijen primenom dubokog učenja. Predikcija SUR koristeći SUR-FeatNet model dubokog učenja ilustrovana je na slici 3.



Slika 3. Upotreba SUR-FeatNet modela za predikciju SUR krive

Inception neuralna mreža se koristi za izdvajanje obeležja iz izvorne i komprimovane slike [5, 7]. Nakon toga, vektori obeležja se porede korišćenjem neuralne mreže. Dobijeni SUR skor se arhivira za svaki nivo degradacije. Na kraju ovog procesa dobija se SUR vektor sa 100 vrednosti koje odgovaraju svakom nivou degradacije, kao što je prikazano na slici 4. Ova slika dodatno prikazuje određivanje pozicije prve JND tačke (JND #1) za prvu sliku u MCL-JCI bazi, gde se pozicija određuje na osnovu 50% od maksimalne vrednosti SUR krive. U ovom primeru JND #1 se dobija za nivo degradacije 77 (faktor kvaliteta JPEG kompresije je 23), što odgovara JND #1 tački dobijenoj u subjektivnim testovima [5].



Slika 4. Ilustracija određivanja prve JND tačke korišćenjem SUR krive

3. Rezultati i analiza rezultata

Kako bi se rezultati objektivne evaluacije učinili nezavisnim od sadržaja originalne slike, autori iz [3] su predložili da se koristi diferencijalni PSNR (DPSNR), a koji se dobija kao razlika između PSNR i predikcije PSNR JND #1:

$$DPSNR = PSNR - PSNR \text{ JND } \#1. \quad (12)$$

DPSNR vrednosti mogu biti pozitivne i negativne. Pozitivne vrednosti odgovaraju slikama dobrog kvaliteta ($PSNR > PSNR \text{ JND } \#1$), dok negativne vrednosti odgovaraju slikama lošijeg kvaliteta. Takođe, DPSNR se može razmatrati kao JND mera za objektivnu procenu kvaliteta slike.

U tabeli 1 dati su kvantitativni pokazatelji stepena slaganja između subjektivnih i PSNR/DPSNR objektivnih skorova kvaliteta za šest baza slika – LIVE [8], CSIQ [9], VCL@FER [10], TID2008 [11], LWIR [12] i MCL-JCI [6]. Kao kvantitativni pokazatelji koriste se Pirsonov koeficijent linearne korelaciјe (engl. *Pearson's Linear Correlation Coefficient*, PLCC), Spirmanova korelacija rangova (engl. *Spearman's Rank-Order Correlation Coefficient*, SROCC), srednja apsolutna greška (engl. *Mean Absolute Error*, MAE), koren srednje kvadratne greške (engl. *Root Mean Square Error*, RMSE) i stepen odstupanja (engl. *Outlier Ratio*, OR) između subjektivnih i objektivnih skorova nakon nelinearne regresije korišćenjem logističke funkcije sa četiri parametra [13]. Pored performansi DPSNR mera, u tabeli su date performanse konvencionalne PSNR mere, kao i tri mere koje koriste osobine HVS – PSNR-HVS [14], PSNR-HVS-M [15] i WNMAE [16]. WNMAE mera koristi JND model na nivou piksela, dok PSNR-HVS i PSNR-HVS-M razmatraju funkciju osetljivosti HVS na kontrast i maskiranje kontrasta. Za svaku od baza i po svakom od kriterijuma dva najbolja rezultata su podebljana.

Tabela 1. Poređenje performansi objektivnih mera na šest baza

Baza	Mera	PLCC	SROCC	MAE	RMSE	OR [%]
LIVE	PSNR	0.8879	0.8809	11.3594	14.6532	12.5714
	WNMAE	0.9143	0.9113	9.9537	12.9013	5.7143
	PSNR-HVS	0.9585	0.9478	7.1802	9.0760	1.1429
	PSNR-HVS-M	0.9752	0.9650	5.5549	7.0493	0.0000
	DPSNR (SI _{mean})	0.9649	0.9565	6.5225	8.3637	1.1429
	DPSNR (SF _{mean})	0.9636	0.9528	6.6269	8.5199	0.5714
	DPSNR (SUR-FeatNet)	0.9756	0.9678	5.4674	6.9950	0.0000
CSIQ	PSNR	0.8906	0.8879	0.0964	0.1391	31.3333
	WNMAE	0.8971	0.8962	0.0946	0.1352	34.0000
	PSNR-HVS	0.9577	0.9400	0.0603	0.0880	22.6667
	PSNR-HVS-M	0.9733	0.9512	0.0501	0.0702	20.0000
	DPSNR (SI _{mean})	0.9707	0.9510	0.0547	0.0735	19.3333
	DPSNR (SF _{mean})	0.9740	0.9543	0.0513	0.0694	17.3333
	DPSNR (SUR-FeatNet)	0.9767	0.9560	0.0515	0.0656	15.3333
VCL@FER	PSNR	0.6041	0.6040	13.6027	16.7039	69.5652
	WNMAE	0.6252	0.6279	13.2803	16.3580	71.7391
	PSNR-HVS	0.8741	0.8775	7.8178	10.1823	48.5507
	PSNR-HVS-M	0.9408	0.9388	5.5695	7.1051	33.3333
	DPSNR (SI _{mean})	0.8269	0.8262	9.2646	11.7856	52.1739
	DPSNR (SF _{mean})	0.8465	0.8456	8.8195	11.1601	52.8986
	DPSNR (SUR-FeatNet)	0.8858	0.8878	7.5386	9.7268	41.3043
TID2008	PSNR	0.8698	0.8717	0.6768	0.8403	NA
	WNMAE	0.8967	0.9017	0.5933	0.7540	
	PSNR-HVS	0.9720	0.9577	0.3139	0.4001	
	PSNR-HVS-M	0.9823	0.9338	0.2513	0.3186	
	DPSNR (SI _{mean})	0.9489	0.9215	0.4317	0.5374	
	DPSNR (SF _{mean})	0.9557	0.9259	0.3828	0.5014	
	DPSNR (SUR-FeatNet)	0.9287	0.8834	0.4276	0.6319	
	DPSNR (SUR-FeatNet)*	0.9625	0.9185	0.3492	0.4580	
LWR	PSNR	0.8377	0.8146	0.4362	0.5650	59.0000
	WNMAE				NA	
	PSNR-HVS	0.8238	0.8018	0.4573	0.5865	63.0000
	PSNR-HVS-M	0.8389	0.8135	0.4492	0.5631	65.0000
	DPSNR (SI _{mean})	0.9481	0.9238	0.2596	0.3290	45.0000
	DPSNR (SF _{mean})	0.8927	0.8705	0.3765	0.4663	56.0000
	DPSNR (SUR-FeatNet)	0.9478	0.9216	0.2666	0.3297	46.0000
MCL-JCI	PSNR	0.4721	0.4486	0.1907	0.2288	NA
	WNMAE	0.4783	0.4665	0.1899	0.2279	
	PSNR-HVS	0.7679	0.7506	0.1328	0.1662	
	PSNR-HVS-M	0.8584	0.8456	0.1026	0.1331	
	DPSNR (SI _{mean})	0.7973	0.7930	0.1222	0.1566	
	DPSNR (SF _{mean})	0.9058	0.8977	0.0852	0.1099	
	DPSNR (SUR-FeatNet)	0.9559	0.9552	0.0556	0.0762	

* - bez četiri slike koje potiču od originala i25.bmp (nije slika prirodne scene)

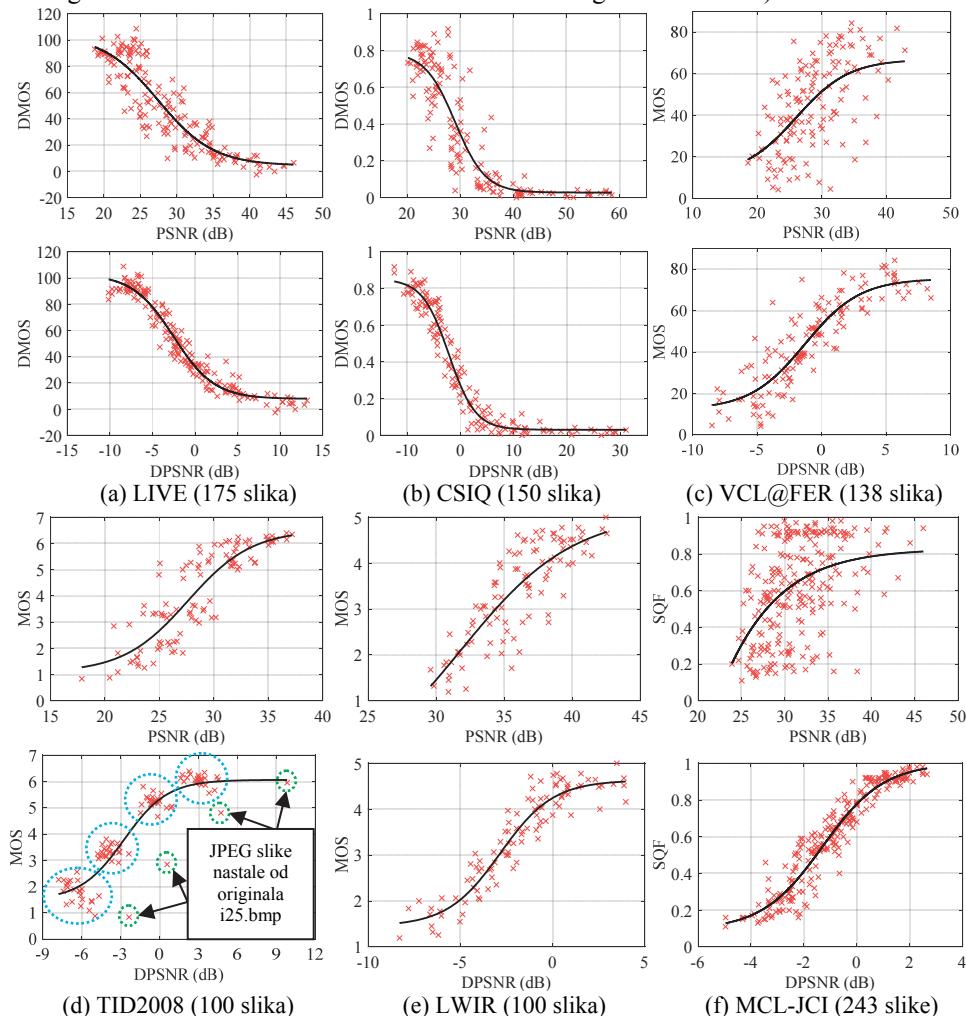
Iz tabele 1 se može zaključiti da se uzimanjem u obzir prve JND tačke dobijaju DPSNR skorovi koji imaju značajno veći stepen slaganja od skorova dobijenih primenom konvencionalnog PSNR pristupa kod koga rezultati značajno zavise od sadržaja izvornog signala [17]. Dobitak je ostvaren nezavisno od toga na koji način je izvršena predikcija pozicije prve JND tačke – korišćenjem SI_{mean} , SF_{mean} ili SUR-FeatNet pristupa. Ako se razmatra stepen slaganja skorova tri DPSNR pristupa i subjektivnih skorova, osim na LWIR bazi infracrvenih slika, on je najveći ukoliko se za predikciju koristi SUR-FeatNet pristup sa dubokim učenjem. Razlika u performansama DPSNR pristupa je naročito izražena na VCL@FER i MCL-JCI bazama. Ako se kao kvantitativna mera posmatra koeficijent PLCC, može se zaključiti da je DPSNR (SUR-FeatNet) pristup najlošije rezultate ostvario na VCL@FER bazi ($PLCC=88.58\%$), što je verovatno posledica loših performansi konvencionalne PSNR mere ($PLCC=60.41\%$). Na preostalim bazama koeficijent korelacije PLCC je veći od 94%. Iako su performanse PSNR mere na MCL-JCI bazi loše ($PLCC=47.21\%$), performanse DPSNR (SUR-FeatNet) pristupa su značajno bolje od PSNR, ali i od ostalih pristupa, $PLCC=95.59\%$, a čemu je doprinelo obučavanje SUR-FeatNet modela na ovoj bazi.

Od standardnih pristupa koji su analizirani najbolje slaganje sa rezultatima subjektivnih testova ostvareno je primenom PSNR-HVS-M objektivne mere. Performanse DPSNR (SUR-FeatNet) pristupa su u nivou performansi ove mere na LIVE, CSIQ i TID2008 bazama, a bolje su na LWIR i MCL-JCI bazama. Najlošije performanse ima PSNR objektivna procena kvaliteta, dok su performanse WNMAE objektivne mere nešto bolje. Kvantitativni pokazatelji slaganja subjektivnih i WNMAE objektivnih skorova ne mogu da se sračunaju za LWIR bazu jer je WNMAE mera namenjena proceni kvaliteta slika u boji, a infracrvene slike LWIR baze su u nijansama sive.

Na slici 5 prikazani su dijagrami rasipanja subjektivnih i objektivnih skorova kvaliteta zajedno sa optimalnim regresionim funkcijama na šest baza koje sadrže slike sa JPEG kompresijom. Na ovim dijagramima svaka tačka odgovara jednoj test (komprimovanoj) slici, gde su na apscisi vrednosti objektivnih, a na ordinati vrednosti subjektivnih skorova kvaliteta. U ovim bazama rezultati subjektivnih testova dati su kroz prosečne subjektivne skorove – MOS (engl. *Mean Opinion Score*), diferencijalne MOS skorove, DMOS, i SQF (engl. *Stair Quality Function*) skorove. Od objektivnih mera prikazani su rezultati konvencionalne PSNR mere i DPSNR mere dobijene korišćenjem SUR-FeatNet algoritma predikcije pozicije prve JND tačke.

Sa slike 5 se može zaključiti da se rasipanje skorova kvaliteta značajno smanjuje primenom DPSNR mere u odnosu na konvencionalni PSNR pristup. Rasipanje oko regresione krive je najmanje na LIVE i CSIQ bazama, a kod kojih su rezultati subjektivnih skorova predstavljeni kroz diferencijalne (DMOS) skorove kvaliteta. Takođe, može se zaključiti da se rasipanje značajno smanjilo i na LWIR bazi koja sadrži slike iz infracrvenog dela elektromagnetnog spektra, iako je SUR-FeatNet model obučen na slikama iz vidljivog dela (MCL-JCI baza). Uočava se značajno smanjenje rasipanja na MCL-JCI bazi, a na kojoj je i izvršeno obučavanje. Interesantni su i rezultati na TID2008 bazi gde su se skorovi nakon primene DPSNR pristupa grupisali u četiri skupa (oivičena na slici 5d), a koji odgovaraju nivoima degradacije (četiri nivoa) korišćenim prilikom formiranja baze. Takođe, mogu se uočiti četiri tačke koje odstupaju od trenda većine. Dodatnom analizom utvrđeno je da te četiri tačke (obeležene na slici 5d) odgovaraju

komprimovanim verzijama izvorne slike i25.bmp, a koja je veštački generisana (u treningu SUR-FeatNet modela nisu korišćene veštački generisane slike).



Slika 5. Dijagrami rasipanja subjektivnih (MOS/DMOS/SQF) i objektivnih (PSNR/DPSNR) skorova kvaliteta na šest baza slika sa JPEG kompresijom

4. Zaključak

Uvođenje pozicije prve JND tačke u objektivnu procenu kvaliteta JPEG slika dovelo je do značajnog unapređenja stepena slaganja subjektivnih i PSNR objektivnih skorova kvaliteta. Unapređenje je ostvareno zbog smanjenja zavisnosti objektivnih PSNR procena kvaliteta od sadržaja izvornog signala. Stepen unapređenja zavisi od načina predikcije pozicije prve JND tačke, kao granice između kompresije bez i sa gubitkom vizuelnih informacija. Unapređenje je ilustrovano primenom tri pristupa predikcije na šest baza koje sadrže slike sa JPEG kompresijom. Najveći dobitak je ostvaren primenom

predikcije na osnovu krive zadovoljstva korisnika komprimovanim sadržajem dobijene primenom dubokog učenja.

Obučavanje SUR-FeatNet modela sa dubokim učenjem izvršeno je na javno dostupnoj JND bazi sa 50 izvornih slika. Za očekivati je da će performanse modela, a i objektivnih procena, biti dodatno unapredene proširenjem skupa za obučavanje sa slikama i rezultatima JND testova iz KonJND_1k baze (sa 504 slike i JND testovima na JPEG slikama). Dodatno se uvedeni pristup procene kvaliteta korišćenjem pozicije prve JND tačke može proveriti i na BPG tipu kompresije jer KonJND_1k baza sadrži i rezultate JND testova sa ovim tipom kompresije (na 504 slike).

Performanse novouvedene objektivne mere (diferencijalni PSNR), osim od predikcija vrednosti PSNR prvih JND tačaka, zavise i od performansi konvencionalne PSNR mere. Ukoliko su performanse PSNR mere loše (kao što je to slučaj na VCL@FER bazi), za očekivati su lošije performanse diferencijalnog pristupa u proceni kvaliteta. Zbog toga se u budućem radu može istražiti primena diferencijalnog pristupa kod drugih objektivnih mera procene kvaliteta.

Literatura

- [1] B. Bondžulić, V. Lukin, D. Bujaković, F. Li, S. Kryvenko, and B. Pavlović, “On visually lossless JPEG image compression”, in Proc. *Zooming Innov. Consum. Technolog. Conf.*, pp. 113-118, 2023. DOI: 10.1109/ZINC58345.2023.10174090
- [2] H. Liu, Y. Zhang, H. Zhang, C. Fan, S. Kwong, C.-C. J. Kuo, and X. Fan, “Deep learning based picture-wise just noticeable prediction model for image compression”, *IEEE Trans. Image Process.*, vol. 29, pp. 641-656, 2020.
DOI: 10.1109/TIP.2019.2933743
- [3] B. Bondžulić, B. Pavlović, N. Stojanović, and V. Petrović, “Picture-wise just noticeable difference prediction model for JPEG image quality assessment”, *Vojnotehnički glasnik - Mil. Tech. Cour.*, vol. 70, no. 1, pp. 62-86, 2022. DOI: 10.5937/vojtehg70-34739
- [4] B. Pavlović, B. Bondžulić, N. Stojanović, V. Petrović, and D. Bujaković, “Prediction of the first just noticeable difference point based on simple image features”, in Proc. *Zooming Innov. Consum. Technolog. Conf.*, pp. 125-130, 2023.
DOI: 10.1109/ZINC58345.2023.10173865
- [5] H. Lin, V. Hosu, C. Fan, Y. Zhang, Y. Mu, R. Hamzaoui, and D. Saupe, “SUR-FeatNet: Predicting the satisfied user ratio curve for image compression with deep feature learning”, *Qual. User Exp.*, vol. 5, no. 5, pp. 1-23, 2020.
DOI: 10.1007/s41233-020-00034-1
- [6] L. Jin, J.Y. Lin, S. Hu, H. Wang, P. Wang, I. Katsavounidis, A. Aaron, and C.-C. J. Kuo, “Statistical study on perceived JPEG image quality via MCL-JCI dataset construction and analysis”, in Proc. *IS&T Int. Symp. Electron. Imaging*, art. number: IQSP-222, 2016. DOI: 10.2352/ISSN.2470-1173.2016.13.IQSP-222
- [7] O. Zelmati, *Subjektivna i objektivna procena kvaliteta slika iz infracrvenog dela elektromagnetnog spektra*, Doktorska disertacija, Univerzitet odbrane u Beogradu, Vojna akademija, 2023.
- [8] H.R. Sheikh, M.F. Sabir, and A.C. Bovik, “A statistical evaluation of recent full reference image quality assessment algorithms”, *IEEE Trans. Image Process.*, vol. 15, no. 11, pp. 3440-3451, 2006. DOI: 10.1109/TIP.2006.881959

- [9] E.C. Larson and D.M. Chandler, "Most apparent distortion: Full-reference image quality assessment and the role of strategy", *J. Electron. Imaging*, vol. 19, no. 1, art. number: 011006, 2010. DOI: 10.1117/1.3267105
- [10] A. Zarić, N. Tatalović, N. Brajković, H. Hlevnjak, M. Lončarić, E. Dumić, and S. Grgić, "VCL@FER image quality assessment database", *Automatika*, vol. 53, no. 4, pp. 344-354, 2012. DOI: 10.7305/automatika.53-4.241
- [11] N. Ponomarenko, V. Lukin, A. Zelensky, K. Egiazarian, M. Carli, and F. Battisti, "TID2008 - A database for evaluation of full-reference visual quality assessment metrics", *Adv. Mod. Radioelectron.*, vol. 10, no. 4, pp. 30-45, 2009.
- [12] O. Zelmati, B. Bondžulić, B. Pavlović, I. Tot, and S. Merrouche, "Study of subjective and objective quality assessment of infrared compressed images", *J. Electr. Eng.*, vol. 73, no. 2, pp. 73-87, 2022. DOI: 10.2478/jee-2022-0011
- [13] *Objective perceptual assessment of video quality: Full reference television*, ITU-T Telecommunication Standardization Sector, 2004.
- [14] K. Egiazarian, J. Astola, N. Ponomarenko, V. Lukin, F. Battisti, and M. Carli, "Two new full-reference quality metrics based on HVS", in Proc. 2nd Int. Workshop Video Process. Qual. Metrics Consum. Electron. – VPQM, pp. 1-4, 2006.
- [15] N. Ponomarenko, F. Silvestri, K. Egiazarian, M. Carli, J. Astola, and V. Lukin, "On between-coefficient contrast masking of DCT basis function", in Proc. 3rd Int. Workshop Video Process. Qual. Metrics Consum. Electron. – VPQM, pp. 1-4, 2007.
- [16] S. Toprak and Y. Yalman, "A new full-reference image quality metric based on just noticeable difference", *Comput. Stand. Interfaces*, vol. 50, pp. 18-25, 2017. DOI: 10.1016/j.csi.2016.08.003
- [17] Q. Huynh-Thu and M. Ghanbari, "Scope of validity of PSNR in image/video quality assessment", *Electron. Lett.*, vol. 44, no. 13, pp. 800-801, 2008. DOI: 10.1049/el:20080522

Abstract: In this paper, it is shown that the application of the just noticeable difference threshold can significantly improve the performance of the Peak Signal-to-Noise Ratio (PSNR) in the quality assessment of JPEG compressed images. The threshold is determined globally, at the level of the complete image, by predicting the PSNR corresponding to the boundary between visually lossless and visually lossy compression. In the prediction, simple features (spatial frequency and spatial information) derived from the original uncompressed image and the satisfied user ratio curve obtained by applying deep learning model are used. The improvement is illustrated through scatter plots and quantitative indicators for six publicly available image databases with the results of subjective tests, among which one database contains images from the infrared part of the electromagnetic spectrum. The degree of improvement depends on the just noticeable difference threshold prediction method and the image database used. Applying a prediction derived from simple features provides slightly worse results than the results when a prediction based on the satisfied user ratio curve is used.

Keywords: Just Noticeable Difference (JND), JPEG compression, objective quality assessment, Peak Signal-to-Noise Ratio (PSNR)

APPLICATION OF JUST NOTICEABLE DIFFERENCE THRESHOLD IN THE OBJECTIVE QUALITY ASSESSMENT OF JPEG COMPRESSED IMAGES

Boban Bondžulić, Nenad Stojanović