

Usporedba odabranih metoda za detekciju rubova na digitalnim slikama

Kokot, Enrico

Master's thesis / Diplomski rad

2024

Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: **University of Pula / Sveučilište Jurja Dobrile u Puli**

Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:137:726890>

Rights / Prava: [Attribution 4.0 International](#)/[Imenovanje 4.0 međunarodna](#)

Download date / Datum preuzimanja: **2024-09-28**



Repository / Repozitorij:

[Digital Repository Juraj Dobrila University of Pula](#)



Sveučilište Jurja Dobrile u Puli

Tehnički fakultet

ENRICO KOKOT

**USPOREDBA ODABRANIH METODA ZA DETEKCIJU RUBOVA NA DIGITALNIM
SLIKAMA**

Diplomski rad

Pula, rujan 2024. godine

Sveučilište Jurja Dobrile u Puli

Tehnički fakultet

ENRICO KOKOT

**USPOREDBA ODABRANIH METODA ZA DETEKCIJU RUBOVA NA DIGITALNIM
SLIKAMA**

Diplomski rad

JMBAG: 0009068626, redoviti student

Studijski smjer: Računarstvo

Kolegij: Digitalna obrada i analiza slike

Znanstveno područje: Tehničke znanosti

Znanstveno polje: Računarstvo

Znanstvena grana: Obradba informacija

Mentor: doc. dr. sc. Nikola Lopac

Pula, rujan 2024. godine

Doc. dr. sc. Nikola Lopac
(Ime i prezime nastavnika)

Digitalna obrada i analiza slike
(Predmet)

Sveučilište Jurja Dobrile u Puli

Tehnički fakultet u Puli

ZADATAK TEME DIPLOMSKOG RADA

Pristupniku

MBS:

Enrico Kokot

0009068626

Studentu Tehničkog fakulteta u Puli, izdaje se zadatak za diplomski rad – tema rada pod nazivom:

USPOREDBA ODABRANIH METODA ZA DETEKCIJU RUBOVA NA DIGITALNIM SLIKAMA

Sadržaj zadatka:

U radu je potrebno usporediti odabrane metode za detekciju rubova na digitalnim slikama. Odabrane metode za detekciju rubova, poput Sobel, Prewitt i Laplace operatora te Canny algoritma, potrebno je opisati, implementirati i primijeniti na skup testnih slika pri različitim razinama šuma. Potrebno je provesti analizu postignutih rezultata te provesti evaluaciju i diskusiju učinkovitosti odabranih metoda u detekciji rubova na slikama.

Rad obraditi sukladno odredbama Pravilnika o završnom/diplomskom radu Sveučilišta u Puli.

Enrico Kokot

(Ime i prezime studenta):

Redovni

(status izvanredni/redovni)

Diplomski sveučilišni studij Računarstvo

(studij)

Datum: 9. ožujka 2024.

Potpis nastavnika



Sadržaj

1. Uvod.....	1
2. Detekcija rubova na digitalnim slikama	3
2.1. Modeli rubova	4
2.2. Bazična detekcija rubova	9
3. Metode za detekciju rubova na digitalnim slikama	11
3.1. Sobel operator	11
3.2. Prewitt operator.....	13
3.3. Laplace operator	14
3.4. Canny algoritam.....	15
4. Rezultati i diskusija.....	17
4.1. Skup testnih slika	18
4.1.1. Houses.....	18
4.1.2. Cameraman	18
4.1.3. Pepper	18
4.1.4. Mandrill	19
4.1.5. Barbara	19
4.1.6. Fish.....	19
4.1.7. Gate	19
4.2. Usporedba rezultata primjena algoritama za detekciju rubova.....	27
4.2.1. Rezultati primjene Sobel operatora.....	29
4.2.2. Rezultati primjene Prewitt operatora	31
4.2.3. Rezultati primjene Laplace operatora	32
4.2.4. Rezultati primjene Canny algoritma	33
4.3. Usporedba rezultata među slikama.....	33
5. Zaključak	62
Literatura	63
Popis slika	64
Popis tablica	68
Sažetak	69
Abstract	70

1. Uvod

U današnjem svijetu često se mogu čuti priče i predviđanja o umjetnoj inteligenciji i kako će ona polako zamijeniti sve bazične i repetitivne ljudske poslove. Poduzetnici se često raduju zamjenjivanju skupo plaćenih radnika kao što su programeri u svrhu generiranja većih profita. Takva obećanja polako nalijeću na realna ograničenja ali nitko ne zna kada će doći do velikog skoka u napretku koji će donijeti umjetnu inteligenciju koja je neprepoznatljiva od one čovjekove. Društvo ne može čekati na taj dan već mora paralelno razvijati tehnologije koje će omogućiti umjetnoj inteligenciji da iskoristi sve potencijale koje ona nudi. Nema razloga zašto bi u tom trenutku prepreka na putu trebala biti npr. nemogućnost računala da prepozna okolinu oko sebe i time spriječili razvoj androida koji mogu obavljati razne za čovjeka monotone ili opasne poslove.

Prepoznavanje vlastite okoline je ovdje presudna značajka zato što bi omogućila inteligentnom robotu da operira unutar našeg svijeta. Naravno, ova tehnologija nije ništa strano u današnjem svijetu i redovito ju se može vidjeti u popularnoj kulturi, od sve prisutnijih i više obećanih autonomnih vozila do današnjih skladišta u kojima nekada operiraju manjinski ljudski zaposlenici a većinom oni robotski.

Detekcija rubova na slici je samo dio cijele slike koja robotu omogućava da odluči svoj sljedeći potez ali je time i nezamjenjiv korak cijelog procesa. Primjena detekcije rubova nije samo ovdje već i u slučaju bržeg izvršavanja raznih modela za treniranje kako bi se umjetna inteligencija što brže naučila koristeći dostupne podatke kojih je u današnjem digitalnom dobu sve više. Stoga se može reći da je ovo jedna grana tehnologije koja čini značajan dio našeg života iako prosječni čovjek toga ne mora biti svjestan, možda jednog dana kada se većina poslova bude temeljila na održavanju i unaprjeđivanju robota koji nam omogućuju lagodniji život.

Ovaj rad se sastoji od pet poglavlja. U prvom poglavlju je opisana motivacija za istraživanjem područja detekcije rubova i kako se obrađeno područje uklapa u širu sliku. Drugo poglavlje uvodi čitatelja u problematiku detekcije rubova na slikama opisivanjem nastanka i oblika rubova na slikama. Treće poglavlje opisuje četiri odabrane metode za detekciju rubova na slikama objašnjavanjem njihovih parametara i implementacija. U četvrtom poglavlju se opisane metode primjenjuju na odabrane testne slike s različitim vrstama šuma kako bi se mogla sagledati efikasnost odabranih

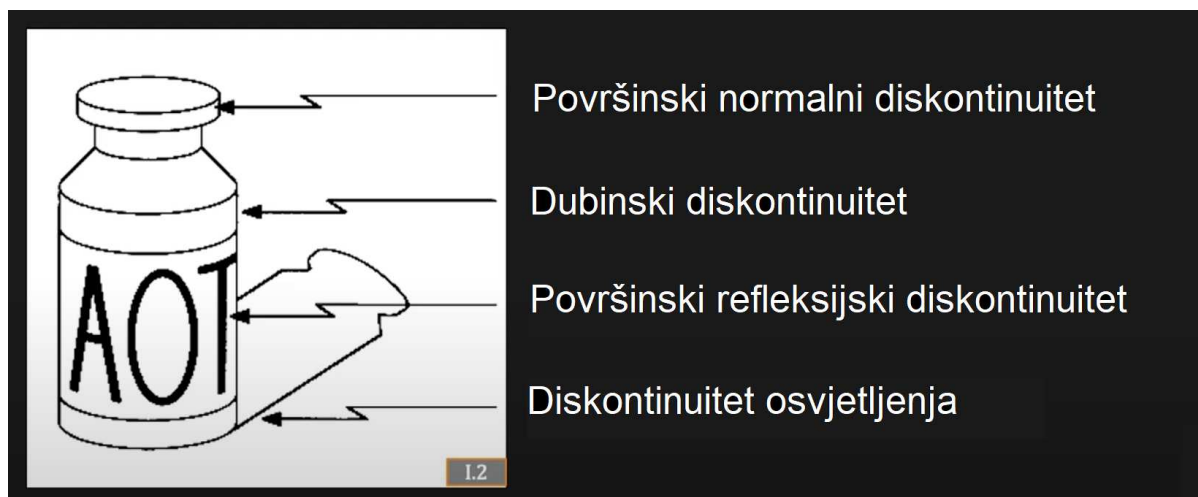
metoda u više ili manje zahtjevnim uvjetima. Ocjene se daju na temelju metode za uspoređivanje sličnosti među slikama. Metode se primjenjuju i na dvije posebne slike iz skupa podvodnih fotografija koje daju uvid u sposobnost metoda u realnim uvjetima za potrebe korištenja računalnog vida pod vodom. Peto poglavlje sadrži zaključak u kojem su dani pregled obrađenog i završni komentari.

2. Detekcija rubova na digitalnim slikama

Rubom na slici se smatra zakrivljena linija gdje dolazi do nagle promjene u svjetlini ili prostornoj derivaciji svjetline uzrokovanom jednim od sljedećih događaja na površini objekta prikazanog na slici:

- Površinski normalni diskontinuitet (*engl. surface normal discontinuity*) nastaje kada dvije površine istog materijala imaju različite orijentacije i time dobivaju različite količine svjetla iz istog izvora.
- Dubinski diskontinuitet (*engl. depth discontinuity*) nastaje na rubu između dva objekta od kojih se jedan nalazi ispred nekog drugog.
- Površinski refleksijski diskontinuitet (*engl. surface reflection discontinuity*) nastaje zbog razlika u materijalima koji posjeduju različite sposobnosti reflektiranja svjetla.
- Diskontinuitet osvjetljenja (*engl. illumination discontinuity*) nastaje na rubovima sjena stvorenih objektima prisutnim na slici (Nayar, YouTube: What is an Edge? | Edge Detection 2021).

Slika 1 prikazuje opisane fenomene na jednostavnoj slici.



Slika 1. Fenomeni stvaranja rubova

Izvor: Autor modificirao prema (Nayar, YouTube: What is an Edge? | Edge Detection 2021)

Problem detekcije rubova je podvrsta problema segmentacije gdje je cilj razdvojiti sliku u njoj pripadajuće regije ili objekte. Segmentacija netrivialnih slika se smatra jednim od najtežih zadataka u problematici obrade slika. Dva bazična svojstva vrijednosti


intenziteta na slikama na kojima se baziraju algoritmi za segmentaciju jesu sličnost i nepovezanost (Gonzalez i Woods 2008).

Algoritmi za segmentaciju bazirani na sličnosti se temelje na dijeljenju slike na regije koje su slične što se utvrđuje prethodno definiranim kriterijima. Metode obuhvaćene ovim pristupom su pronalaženje granične vrijednosti (*engl. thresholding*), rast regija i skupljanje regija. Algoritmi bazirani na nepovezanosti dijele sliku na temelju naglih promjena intenziteta kao što su rubovi. U praksi se ove metode koriste zajedno kako bi se postigle bolje performanse. Jedan od primjera su tehnike koje istovremeno koriste prepoznavanje rubova i pronalaženje granične vrijednosti (Gonzalez i Woods 2008).

2.1. Modeli rubova

Pronalaženje rubova je pristup koji se najčešće koristi za dijeljenje slike temeljeno na naglim lokalnim promjenama u intenzitetu. Rubovi se mogu kategorizirati po njihovim profilima intenziteta koje dijelimo na tri kategorije: nagli rubovi, rampni rubovi i krovni rubovi (Gonzalez i Woods 2008, Forsyth i Ponce 2011).


Nagli rub (*engl. step edge*) uključuje promjenu između dvije razine intenziteta koja se idealno događa na udaljenosti od jednog piksela. Nagli rubovi se pojavljuju u računalno generiranim slikama koje se koriste za modeliranje krutih tvari (*engl. solids*) i animacijama. Ovakvi čisti i idealni rubovi se mogu dogoditi na širini od jednog piksela dok god nije primijenjena dodatna obrada slike poput izgladivanja. Digitalni nagli rubovi se često koriste kao modeli rubova u razvoju algoritama (Gonzalez i Woods 2008). Slika 2 prikazuje dio vertikalnog naglog ruba i njegov horizontalni profil intenziteta kroz rub.



Slika 2. Nagli rub


Izvor: Izradio autor

Krovni rub (*engl. roof edge*) je modeliran kao linija kroz regiju s bazom krovnog ruba koja biva određena širinom i oštrinom linije. U limitu, kada je baza širine jednog piksela, krovni rub je ništa više nego linija širine jednog piksela koja prolazi kroz neku regiju slike. Krovni rubovi nastaju na slikama udaljenosti (*engl. range images*) gdje se uži objekti koji se nalaze bliže senzoru imaju jači intenziteta od pozadinskih objekata. Krovni model nalazi svoju primjenu u digitalizaciji linijskih crteža i u satelitskim slikama gdje se uže značajke poput cesta mogu modelirati ovim tipom rubova (Gonzalez i Woods 2008). Na Slici 3 je vidljiv dio krovnog ruba i njegov horizontalni profil intenziteta kroz rub.




Slika 3. Krovni rub
Izvor: Izradio autor

Rampni rub (*engl. ramp edge*) je treći model ruba i pojavljuje se u praksi digitalnih slika koje sadrže rubove nastale prirodnim pojavama poput zamućenja leće i modeliran je tako da ima profil intenziteta rampe. Nagib rampe je obrnuto proporcionalan sa stupnjem zamućenja na rubu. Ovaj model nema crtu širine jednog piksela. Umjesto toga, rubna točka je bilo koja točka koja se nalazi na rampi a rubni segment bi bio skup povezanih točaka koje zadovoljavaju dani uvjet (Gonzalez i Woods 2008). Na Slici 4 je vidljiv dio rampnog ruba i njegov horizontalni profil intenziteta kroz rub.



Slika 4. Rampni rub
Izvor: Izradio autor

Na Slici 5 moguće je vidjeti kako prelazak iz mračnog dijela slike u svijetli dio slike utječe na profil horizontalnog intenziteta. Primjećuje se da je prva derivacija pozitivna gdje rampa kreće i jednaka nuli u mjestima konstantnog intenziteta. Druga derivacija je pozitivna na početku rampe, jednaka nuli duž rampe, negativna na mjestu prestanka rampe i jednaka nuli na mjestima konstantnog intenziteta. Predznaci vrijednosti bi bili obrnuti za rub koji prelazi iz pozitivnih u negativne vrijednosti. Točka križanja između osi nultog intenziteta i linije koja se pruža između ekstrema druge derivacije označava točku zvanu prolazak kroz nulu (*engl. zero crossing*) druge derivacije (Gonzalez i Woods 2008).




Slika 5. Karakteristike derivacija rampnog ruba
Izvor: Izradio autor

Iz proučenih karakteristika rampnih rubova može se zaključiti da magnituda prve derivacije može biti korištena za pronalaženje postojanja ruba u nekoj točki na slici. Slično tome, predznak druge derivacije može biti korišten za utvrđivanje nalazi li se piksel ruba na strani ruba niske ili visoke vrijednosti. Također, druga derivacija ruba sadrži još dva svojstva. Nepoželjna karakteristika je da se ovim putem svakom rubu na slici dodjeljuju dvije vrijednosti. Korisna karakteristika ovog modela ruba je da se njegovi prolasci kroz nulu mogu iskoristiti za pronalaženje središta debelih rubova (Gonzalez i Woods 2008).

Neki modeli rubova koriste glatke prijelaze u i van rampe. Ipak, zaključci koje donose ti modeli su jednaki kao i oni idealnih rampi i rad s idealnim rampama pojednostavljuje teoretske formulacije. Također, svi argumenti dosad primijenjeni na jednodimenzionalnim horizontalnim profilima mogu se primijeniti na rub bilo koje orijentacije na slici definiranjem profila koji je okomit na smjer ruba u točki po želji i interpretiranjem rezultata na isti način kao što je opisano s vertikalnim rubovima (Gonzalez i Woods 2008).

Na Slici 6 moguće je sagledati utjecaj šuma na navedene karakteristike derivacija rampnog ruba. U četiri retka su prikazani jednodimenzionalni horizontalni profil, njegova prva derivacija i njegova druga derivacija gdje je na svakoj slici primijenjen Gaussov šum razine intenziteta 0.0, 0.1, 1.0 i 10.0. Može se primijetiti kako se primjenom oku slabo vidljivom porastu šuma gubi mogućnost pronalaženja maksimuma druge derivacije.



Slika 6. Utjecaj šuma na derivacije rampnog ruba
Izvor: Izradio autor

Slike u praksi mogu sadržavati sva tri oblika rubova. Iako zamućivanje i šum rezultiraju u odstupanju od idealnih oblika, rubovi na slikama koji su relativno oštri i imaju umjerenu razinu šuma imaju slične karakteristike spomenutim modelima rubova. Spomenuti modeli nam omogućuju zapisivanje matematičkih izraza za rubove u razvoju algoritama za obradu slike. Performanse ovih algoritama će ovisiti o razlici između stvarnih rubova prisutnih na slici i modela korištenih u razvoju algoritma.

2.2. Bazična detekcija rubova

Kako bi se rubovi prepoznali potrebno je proći tri temeljna koraka:

- Izgladiti sliku kako bi se šum smanjio i time eliminirali problemi nemogućnosti pronalaženja ključnih informacija iz rampnih rubova.
- Pronaći točke rubova lokalnom operacijom koja izvlači iz slike sve točke koje su potencijalni kandidati da postanu točke rubova.
- Lokalizacija rubova čiji je cilj odabrati iz kandidata za točke rubova samo točke koje su stvarni članovi skupa točaka koje čine rub (Gonzalez i Woods 2008).

Detekcija rubova na slikama se temelji na algoritmima koji pronalaze promjene intenziteta na slikama što može biti postignuto pronalaženjem derivacija prvog ili drugog reda (Gonzalez i Woods 2008). Te promjene su lokalnog intenziteta duž određene orijentacije.

Gradijent je bitna stavka kod pronalaženja rubova koja se bazira na kosini promjene vrijednosti u tom pikselu naprema susjednim pikselima (Szelinski 2022). Sljedeći izraz koristi se za pronalaženje gradijenta neke točke (Gonzalez i Woods 2008):

$$\nabla f \equiv \text{grad}(f) = \begin{bmatrix} g_x \\ g_y \end{bmatrix} = \begin{bmatrix} \frac{\partial f}{\partial x} \\ \frac{\partial f}{\partial y} \end{bmatrix} \quad (1)$$

Rezultat daje vektor koji pokazuje u smjeru najveće stope promjene funkcije f u točki (x, y) na slici. Pronalaženje gradijenta omogućava daljnju obradu odabranog piksela tako da se iz njegovog gradijenta izračuna magnituda. Sljedeći izraz prikazuje formulu za dužinu ili magnitudu vektora koja predstavlja vrijednost stope promjene u smjeru vektora (Gonzalez i Woods 2008):

$$M(x, y) = \text{mag}(\nabla f) = \sqrt{g_x^2 + g_y^2} \quad (2)$$

Posljednja veličina koja se može izračunati iz gradijenta je njegov smjer izmjeren u odnosu na x-os računanjem arkus tangensa dobivenog gradijenta. Sljedeći izraz prikazuje formulu za izračunavanje smjera gradijentnog vektora (Gonzalez i Woods 2008):

$$\alpha(x, y) = \tan^{-1} \begin{bmatrix} g_y \\ g_x \end{bmatrix} \quad (3)$$

Sve navedene operacije kada se primjene nad svakom točkom određene slike kao izlaznu vrijednost imaju sliku jednakih dimenzija gdje svaka točka sadrži vrijednost dobivenu primjenom operacije.

Izračunavanje parcijalnih derivacije nad digitalnim slikama je posebna zadaća. S obzirom na to da se radi o diskretnim veličinama, potrebno je izračunati digitalne aproksimacije parcijalnih derivacija susjedstva neke točke. Kako bi se aproksimirale derivacije za potrebe dobivanja gradijenta koriste se operatori (Gonzalez i Woods 2008).

Roberts križ (engl. *Roberts cross*) bio je jedan od prvih operatora koji je služio za prepoznavanje rubova na digitalnim slikama. Na Slici 7 je prikazan oblik operatora (Gonzalez i Woods 2008).

$$\begin{bmatrix} -1 & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} 0 & -1 \\ 1 & 0 \end{bmatrix}$$

Slika 7. Roberts operator

Izvor: Izradio autor

Može se primijetiti da se svi koeficijenti dvodimenzionalne maske sumiraju u nulu što vodi do zaključka da vraća nulu kao rezultat u područjima konstantnog intenziteta, kao što se i očekuje od derivacijskog/derivativnog operatora (Pound, YouTube - Finding the Edges (Sobel Operator) - Computerphile 2015).

Glavni nedostatak operatora dimenzija 2 x 2 je što im nedostaje simetričnost unutar središnje točke što je karakteristično za operatore dimenzija 3 x 3 što im omogućava da uzmu u obzir prirodu podataka na suprotnim stranama središnje točke i tako dobiju više informacija koje se tiču smjera ruba (Gonzalez i Woods 2008).

3. Metode za detekciju rubova na digitalnim slikama

Modeli rubova koji mogu biti nagli, krovni i rampni te operacije izračunavanja gradijenta, njegove dužine i smjera čine osnovu svih metoda za detekciju rubova na digitalnim slikama gdje svaka od njih na svoj način koristi opisane metode s vlastitim vrijednostima danim u primijenjenom operatoru.

3.1. Sobel operator

Koristi dva kernela dimenzija 3 x 3 koje koristi za konvoluciju originalne slike kako bi se dobile aproksimacije derivacija od kojih jedna prati promjene u horizontalnom a druga u vertikalnom smjeru (Gonzalez i Woods 2008, Russ 2006).

Na Slici 8 prikazan je Sobel operator. Lijeva matrica predstavlja kernel za pronalaženje rubova u okomitom smjeru dok desna matrica predstavlja kernel za pronalaženje rubova na slici u vodoravnom smjeru (Gonzalez i Woods 2008).

$$\begin{bmatrix} -1 & 2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}$$

Slika 8. Sobel operator

Izvor: Izradio autor

Detaljni opis pronalaženja rubova na slici korištenjem Sobelovog operatora uključuje sljedeće korake:

- Algoritam dobiva sliku u sivim tonovima gdje svaki piksel poprima vrijednost između 0 i 255 kako bi se olakšala primjena operatora.
- Svakom pikselu slike biva izračunat gradijent u smjeru obje osi primjenom dvaju Sobelovih operatora. Primjena operatora nad jednim pikselom znači da se taj piksel nalazi u sredini matrice, a njegovi pikseli u direktnom susjedstvu se nalaze na pozicijama koje pokrivaju ostali elementi kernela.
- Vrijednost svakog piksela se tada množi s vrijednošću koja se nalazi na ekvivalentnom mjestu u kernelu i rezultati svih devet izračuna se međusobno zbrajaju za svaki smjer operatora. Iz oblika operatora se može primijetiti da, ukoliko su svi pikseli ispod operatora jednake vrijednosti, tada je rezultat nula zato što jedna strana poništava drugu.
- Iz krajnjih dvaju rezultata se tada uzima apsolutna vrijednost koja predstavlja gradijent u toj točki. Slika 9 prikazuje rezultate primjene obaju Sobelova

operatora u oba smjera nad jednom digitalnom slikom. Može se primijetiti kako je isti rub na jednoj dobivenoj slici vratio visoke vrijednosti dok je u drugoj vratio niske vrijednosti što je posljedica smjera ruba.

- Nad dobivenim vrijednostima gradijenta se tada primjenjuje Pitagorin poučak i dobiva se dužina gradijentnog vektora.
- Dobivene vrijednosti se normaliziraju na vrijednosti između 0 i 255 te se kao rezultat vraća slika istih dimenzija čije su vrijednosti piksela novonastale vrijednosti (Pound, YouTube - Finding the Edges (Sobel Operator) - Computerphile 2015).



Slika 9. Primjena Sobel operatora

Izvor: Autor modificirao prema (Pound, YouTube - Finding the Edges (Sobel Operator) - Computerphile 2015)

Također, dobra praksa kod pripreme slike za primjenu Sobel operatora nad njom je primijeniti Gaussovo zamućenje nad istom kako bi se iz slike izbacile visokofrekvencijske smetnje na koje je pronalaženje rubova osjetljivo (Pound, YouTube - Finding the Edges (Sobel Operator) - Computerphile 2015). Slika 10 prikazuje rezultat primjene Gaussovog zamućenja gdje se može primijetiti eliminacija oštih prijelaza između točaka na slici.



Slika 10. Primjena Gaussovog zamućenja
Izvor: (Microsoft 2020)

3.2. Prewitt operator

Prewitt operator je vrlo blizak Sobel operatoru. Kao i Sobel temelji se na aproksimativnom deriviranju rubova u svakoj točki slike s ciljem dobivanja gradijenta i izračunavanja dužine gradijentnog vektora iz istog. Rezultat je slika istih dimenzija s normaliziranim vrijednostima (Gonzalez i Woods 2008). Na Slici 11 prikazan je Prewitt operator (Gonzalez i Woods 2008).

$$\begin{bmatrix} -1 & -1 & -1 \\ 0 & 0 & 0 \\ 1 & 1 & 1 \end{bmatrix} \begin{bmatrix} -1 & 0 & 1 \\ -1 & 0 & 1 \\ -1 & 0 & 1 \end{bmatrix}$$

Slika 11. Prewitt operator
Izvor: Izradio autor

Prewitt maske su lakše za implementirati od Sobel maska ali razlika u količini izračuna među njima nije značajna. Na Slici 12 može se vidjeti rezultat primjene Prewitt operatora nad slikom.



Slika 12. Primjena Prewitt operatora
Izvor: Autor modificirao prema (Lakshmi i Kumar 2022)

3.3. Laplace operator


Laplace operator se od Sobel i Prewitt operatora razlikuje po tome što on predstavlja aproksimaciju druge derivacije. Kao takav rubovima smatra prolasku kroz nulu na slici (Russ 2006). Na Slici 13 može se vidjeti oblik njegovog operatora (Jähne 2005).

$$\begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}$$

Slika 13. Laplace operator

Izvor: Izradio autor

Ograničenje ovog pristupa je da se ne dobiva smjer rubova. Laplace je također naročito osjetljiv na šum jer se rezultati početnog šuma na slici propagiraju i pogoršavaju prepoznavanje rubova pri svakoj primjeni derivacije. Za potrebe stišavanja šuma se i ovdje koristi Gaussovo zamućenje (Nayar, YouTube: Edge Detection Using Laplacian | Edge Detection 2021). Na Slici 14 se može vidjeti rezultat primjene Gaussovog zamućenja na rub s prisutnim šumom. Prvi redak predstavlja funkcijom prikazan rub opterećen šumom, drugi redak predstavlja funkciju Gaussovog zamućenja primijenjenu na rub, treći redak predstavlja rezultat spajanja objiju funkcija i četvrti redak predstavlja rezultat druge derivacije funkcije iz trećeg reda. Crvena crta na slici predstavlja lokaciju ruba.



Slika 14. Primjena Gaussovog zamućenja za potrebe primjene Laplace
Izvor: (Nayar, YouTube: Edge Detection Using Laplacian | Edge Detection 2021)

Na Slici 15 se može vidjeti rezultat primjene Laplace operatora na fotografiju.



Slika 15. Primjena Laplace operatora
Izvor: (OpenCV 2024)

3.4. Canny algoritam


Ciljevi Canny algoritma za pronalaženje rubova jesu sljedeća tri:

- Niska stopa pogrešaka koja se orijentira na pronalaženje svih rubova koji su definitivno prisutni na slici.
- Točke rubova bi trebale biti dobro lokalizirane što zahtijeva od algoritma da točke rubova koje vrati algoritam budu što bliže središtu stvarnog ruba.
- Povratnu vrijednost treba činiti rub širine jedne točke što se može preformulirati i u ograničenje da broj lokalnih maksimuma neke rubne točke mora biti što manji (Gonzalez i Woods 2008).

Koraci koje pri tome algoritam poduzima jesu sljedeći:

- Početni koraci algoritma su jednaki primjeni Sobel operatora. Dakle, računa se aproksimacija prve derivacije u svakoj od točaka na slici što rezultira gradijentom i duljinom gradijentnog vektora.
- Nakon primjene svih koraka prisutnih i u Sobel pronalaženju rubova slijede dva koraka specifična za Canny algoritam, prvi od kojih je suzbijanje nemaksimalnih vrijednosti. Ovaj se dio bavi filtriranjem svih rubova koji nisu lokalni maksimum u smjeru kretanja ruba. Smjer ruba nam je poznat pošto ga se može izračunati primjenom inverza tangens funkcije nad dobivenim gradijentom. Ovaj korak u konačnici služi tome da u konačnoj slici ostanu samo najtanji rubovi.

- Završni korak algoritma se naziva histereza i ima za cilj eliminirati sve rubove koji su do sada ostali unutar slike, a nisu pravi rubovi. Odluka o njihovom ostavljanju ili izbacivanju se temelji na dvostrukim granicama koje se postavljaju kao granica iznad koje, ako točka na slici ima jednaku vrijednost, može se potvrditi da ta točka uistinu jest dio ruba. S druge strane, ako se točka nalazi ispod donje granice tada je ona odmah eliminirana iz rezultata. Na Slici 16 se može promotriti primjena ove metode na jednodimenzionalnom prikazu vrijednosti gradijenta rubova slike. Zahtjevni dio ove metode se događa na točkama koje se nalaze između dviju granica. Ovdje se promatra je li točka ruba u direktnom susjedstvu neke od točaka koje su prihvaćene kao zadovoljavajuće i kao stvarni rubovi. Ako je taj zahtjev zadovoljen tada i ta točka postaje dio konačnih rubova i može biti ključna za pridruživanje neke druge točke u njenom susjedstvu skupu zadovoljavajućih točaka. Ako točka između dviju granica nema zadovoljen uvjet tada ona biva izbačena iz završnog rezultata.
- Kao rezultat algoritma dobiva se nova slika jednakih dimenzija sa zadovoljavajućim rubovima (Pound, YouTube: Canny Edge Detector - Computerphile 2015).



Slika 16. Metoda histereznog praga

Izvor: Izradio autor

4. Rezultati i diskusija

Opisani algoritmi će biti testirani na skupu slika koji se sastoji od sedam slika s različitim izazovima prilagođenim pronalaženju rubova. Odabrane slike su naziva *Houses*, *Cameraman*, *Pepper*, *Mandrill*, *Barbara*, *Fish* i *Gate*. Među testnim slikama se nalaze i dvije slike dobivene iz skupa podataka podvodnih slika. Sve slike će dodatno biti izmijenjene dodavanjem različitih razina šuma kako bi se testirali rezultati algoritama u manje idealnim uvjetima. Korišteni šumovi su granularni (*engl. speckle*), Gaussov, impulsni (*engl. salt-and-pepper, s&p*) i Poissonov šum.

Granularni šum ima zrnati uzorak i posebna je vrsta šuma koja se uglavnom pojavljuje u satelitskim snimkama (Singh i Shree 2016). Gaussov šum je takav da slučajna varijacija signala slike oko njegove očekivane vrijednosti slijedi normalnu razdiobu. Impulsni šum je takav da se na slici nasumično pojavljuju pikseli vrlo visokih i niskih vrijednosti. Poissonov šum je takav da se njegova prisutnost na slici može modelirati Poissonovim slučajnim procesom (Ivković, i dr. 2018).

Testiranje će se provesti tako da će za svaku sliku biti odrađen sljedeći slijed operacija:

- Na testnu sliku će biti primijenjeni svaki od korištenih oblika šuma. Korišteni parametri za granularni i Gaussov šum su srednja vrijednost od 0,0 i varijanca od 0,01. Impulsni šum koristi parametre koji određuju da šum zauzima 5 % slike dok je parametar omjera postavljen tako da su tamni i svijetli pikseli prisutni u istom omjeru. Poissonov šum ne prima parametre (Walt 2024).
- Sljedeći korak će kao ulaznu vrijednost dobiti skup slika koji se sastoji od slike bez šuma i slika dobivenih primjenom različitih oblika šuma na originalnu sliku.
- Svaki od dvaju novonastalih skupova slika bit će pretvoren u svoj oblik u sivim tonovima.
- Slike u sivim tonovima će biti predane u svaki od odabranih algoritama za raspoznavanje rubova.
- Rezultati će tada biti uspoređeni i komentirani s obzirom na korišteni algoritam i vrstu šumu.

Za potrebe provedbe testiranja nad slikama je korišten Python programski jezik zajedno sa OpenCV, NumPy, Skimage i Matplotlib bibliotekama korištenjem Google Colab web sučelja za programiranje u Python bilježnicama.

4.1. Skup testnih slika

Svaka slika je odabrana na temelju specifičnih izazova koje ona predstavlja:

- *Houses* – geometričnost, jasni rubovi
- *Cameraman* – varijabilni intenzitet od slabih do jakih intenziteta
- *Pepper* – većinom baziran na rubovima stvorenim zbog okluzije pozadine
- *Mandrill* – bogatstvo teksture u krznu
- *Barbara* – različitost tekstura i različitost rubova
- *Fish* – podvodno zamućenje, veliki broj malih subjekata
- *Gate* – podvodno zamućenje, oku jasni rubovi

4.1.1. Houses

Testna slika *Houses* kao svoj sadržaj ima vanjsku površinu nekoliko kuća s izraženim dizajnom i predstavlja jedan od bazičnih testova za algoritam prepoznavanja rubova na slikama s obzirom na njene karakteristike jasnih i pravilnih rubova koji predstavljaju idealne uvjete na slici iz stvarnog svijeta. Na Slici 17 može se promotriti izvorna *Houses* slika zajedno s rezultatima primjene šumova koji su, slijedno, granularni, Gaussov, s&p i Poissonov.

4.1.2. Cameraman

Testna slika *Cameraman* koja kao sadržaj ima fotografiju osobe u crnom kaputu koja koristi kameru na tronošcu se često koristi u svrhu testiranja obrade slika i algoritama sažimanja već dulje od 45 godina. Predstavlja izazov tako da sadrži širok raspon intenziteta boja i time čini izazov algoritmima raspoznavanja rubova koji su preosjetljivi na promjenu intenziteta. Na Slici 18 mogu se promotriti izvorna *Cameraman* slika zajedno s rezultatima primjene šumova koji su, slijedno, granularni, Gaussov, s&p i Poissonov.

4.1.3. Pepper

Testna slika *Pepper* kao sadržaj ima fotografiju paprika žarkih crvenih i zelenih boja naslaganih u blizini objektiva kamere. Ova slika predstavlja izazov u obliku širokog raspona boja ali, isto tako, u obliku nastanka rubova koji ovdje primarno nastaju zbog dubinskog diskontinuiteta prouzročenog rasporedom subjekata na slici. Također, rubovi prisutni na slici su vrlo nepravilnog karaktera. Na Slici 19 mogu se promotriti

izvorna *Pepper* slika zajedno s rezultatima primjene šumova koji su, slijedno, granularni, Gaussov, s&p i Poissonov.

4.1.4. *Mandrill*

Testna slika *Mandrill* dio je SIPI skupa slikovnih podataka sveučilišta Južna Kalifornija koji postoji već od 1977. godine i čiji je glavni cilj podržati istraživanja u znanstvenim granama obrade slika, analize slika i računalnog vida. Slika kao sadržaj ima blisku fotografiju lica primata porijeklom iz Afrike. Izazovi za algoritme prepoznavanja rubova na testnoj slici *Mandrill* predstavljaju široki raspon boja i bogatstvo tekstura na krznu. Na Slici 20 mogu se promotriti izvorna *Mandrill* slika zajedno s rezultatima primjene šumova koji su, slijedno, granularni, Gaussov, s&p i Poissonov.

4.1.5. *Barbara*

Testna slika *Barbara* je još jedna često korištena slika u području obrade i analize slika te kao sadržaj ima fotografiju žene koja sjedi na tlu u sobi punoj različitih predmeta, boja i uzoraka. Slika uzima izazove svih prethodno korištenih slika i sažima ih u jednu. Na Slici 21 mogu se promotriti izvorna *Barbara* slika zajedno s rezultatima primjene šumova koji su, slijedno, granularni, Gaussov, s&p i Poissonov.

4.1.6. *Fish*

Testna slika *Fish* dio je skupa podataka podvodnih slika. Sadržaj slike je jato riba. Izazov prepoznavanja rubova predstavlja zamućenje slike prouzročeno pokretom i podvodnim uvjetima te velik broj subjekata na fotografiji. Na Slici 22 mogu se promotriti izvorna *Fish* slika zajedno s rezultatima primjene šumova koji su, slijedno, granularni, Gaussov, s&p i Poissonov.

4.1.7. *Gate*

Testna slika *Gate* dio je skupa podataka podvodnih slika. Sadržaj slike je podvodna struktura u obliku vrata. Izazov prepoznavanja rubova predstavlja zamućenje slike prouzročeno podvodnim uvjetima i sličnost tonova prisutnih na fotografiji. Na Slici 23 mogu se promotriti izvorna *Gate* slika zajedno s rezultatima primjene šumova koji su, slijedno, granularni, Gaussov, s&p i Poissonov.



a)



b)



c)



d)



e)

Slika 17. Rezultati primjene različitih vrsta šuma na *Houses* sliku: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor



a)



b)



c)



d)




e)

Slika 18. Rezultati primjene različitih vrsta šuma na *Cameraman* sliku: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.


Izvor: Izradio autor




a)




b)



c)




d)




e)

Slika 19. Rezultati primjene različitih vrsta šuma na *Pepper* sliku: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.


Izvor: Izradio autor




a)




b)



c)



d)



e)


Slika 20. Rezultati primjene različitih vrsta šuma na *Mandrill* sliku: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.
Izvor: Izradio autor




a)




b)



c)



d)



e)

Slika 21. Rezultati primjene različitih vrsta šuma na *Barbara* sliku: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor



a)



b)



c)



d)



e)

Slika 22. Rezultati primjene različitih vrsta šuma na *Fish* sliku: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor



a)



b)



c)



d)



e)

Slika 23. Rezultati primjene različitih vrsta šuma na Gate sliku: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovima šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor

4.2. Usporedba rezultata primjena algoritama za detekciju rubova

Za potrebe određivanja mjere prepoznavanja rubova na slikama u različitim uvjetima koristi se mjera indeksa strukture sličnosti (*engl. structural similarity index measure, SSIM*). Navedena metoda se ovdje koristi tako da se slika dobivena primjenom algoritma za prepoznavanje rubova na koju je primijenjen određeni šum uspoređuje sa slikom rubova dobivenom u idealnim uvjetima bez šuma primjenom Canny algoritma čiji su pragovi posebno prilagođeni testiranoj slici. Na Slici 24 mogu se vidjeti slike rubova dobivene podešenim Canny algoritmom. S obzirom na to da rezultat usporedbe predstavlja broj između pozitivne i negativne jedinice, u tablicama koje uspoređuju rezultate se nalaze vrijednosti u obliku postotaka kako bi rezultati bili čitljiviji.

SSIM se temelji na izračunavanju triju faktora unutar slike koji su osvjetljenje, kontrast i struktura. Ukupni indeks je multiplikativna kombinacija prethodna tri faktora. Sljedeći izraz prikazuje jednadžbu za izračunavanje SSIM gdje x i y označavaju dvije slike čiji se faktori uspoređuju, l označava funkciju za izračunavanje sličnosti u osvjetljenju (*engl. luminance*), c označava funkciju za izračunavanje ličnosti u kontrastu (*engl. contrast*), s označava funkciju za izračunavanje sličnosti u strukturi (*engl. structure*) dok α , β i γ označavaju težine koje se pridaju svakom od faktora (MathWorks 2024):

$$SSIM(x, y) = [l(x, y)]^\alpha \cdot [c(x, y)]^\beta \cdot [s(x, y)]^\gamma \quad (4)$$

Spomenute tri funkcije mogu se razložiti sljedećim izrazima gdje μ_x i μ_y označavaju lokalne prosječne vrijednosti, σ_x i σ_y označavaju standardnu devijaciju, σ_{xy} označava kovarijancu, a C_1 , C_2 i C_3 označavaju varijable koje služe stabilizaciji dijeljenja sa nazivnikom niskih vrijednosti (MathWorks 2024):

$$l(x, y) = \frac{2\mu_x\mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1} \quad (5)$$

$$c(x, y) = \frac{2\sigma_x\sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2} \quad (6)$$

$$s(x, y) = \frac{\sigma_{xy} + C_3}{\sigma_x\sigma_y + C_3} \quad (7)$$



a)




b)




c)




d)



e)



f)



g)

Slika 24. Slike rubova dobivene podešenim Canny algoritmom: a) Houses slika. b) Cameraman slika. c) Pepper slika. d) Mandrill slika. e) Barbara slika. f) Fish slika. g) Gate slika.

Izvor: Izradio autor

4.2.1. Rezultati primjene Sobel operatora

Za primjenu Sobel operatora na slike je korišten kod prikazan na Slici 25. Implementacija Sobela u ovom slučaju nije orijentirana prepoznavanju rubova već se svakim pozivom metode dobiva transformacija po specificiranoj osi i potrebno je dodati vlastiti kod kako bi se transformacije po x i y osi spojile u jednu sliku.

Definirana funkcija prima točno jedan argument u obliku slike nad kojom se primjenjuje Sobel operator u smjeru svake od osi. Argumenti koje u ovom slučaju dobiva Sobel metoda OpenCV biblioteke jesu sljedeći:

- `src_gray` – ulazna slika
- `ddepth` – preciznost izlaznih podataka
- `x_order` – red derivacije po x osi
- `y_order` – red derivacije po y osi
- `ksize` – dimenzije korištenog kernela

Nakon dobivanja dviju novih slika koje predstavljaju transformacije po x i y osi, iz dobivenih slika se dobivaju nove slike normaliziranjem njihovih vrijednosti korištenjem `convertScaleAbs` metode i, za kraj, se vraća rezultat `addWeighted` metode koja spaja dvije slike u jednu uzimanjem u obzir težine.


```

def apply_Sobel(image):
    edges_on_x = cv2.Sobel(image, cv2.CV_16S, 1, 0, ksize=3)
    edges_on_y = cv2.Sobel(image, cv2.CV_16S, 0, 1, ksize=3)

    abs_edges_on_x = cv2.convertScaleAbs(edges_on_x)
    abs_edges_on_y = cv2.convertScaleAbs(edges_on_y)

    return cv2.addWeighted(abs_edges_on_x, 0.5, abs_edges_on_y, 0.5, 0)

```

Slika 25. Python kod za Sobel operator

Izvor: Izradio autor

Slike dobivene primjenom Sobel operatora imaju mutnu karakteristiku. Na Slici 26 se može primijetiti zamućenje između originalne *Houses* slike bez prisutnosti šuma i iste slike s primijenjenim operatorom.



Slika 26. Primjena Sobel operatora na *Houses* sliku

Izvor: Izradio autor

Slika 27 prikazuje debljinu rubova primjenom Sobel operatora prouzročenu korištenjem prve derivacije uspoređeno s primjenom Laplace operatora na isti dio *Houses* slike bez prisutnosti šuma.



Slika 27. Usporedba debljine rubova između Sobel i Laplace operatora

Izvor: Izradio autor

Tablica 1 prikazuje usporedbu rezultata između različitih oblika šuma i slika nad kojima je primijenjen Sobel operator. Moguće je uočiti bolje rezultate na *Houses* i *Mandrill* slikama, naročito kod prisutnosti granularnog i Poissonovog šuma. Slike *Cameraman* i *Barbara* imaju značajan pad kvalitete dok se rezultati *Pepper* slike nalaze na samome dnu uz prisutnosti jednoznačenkastih uspješnosti.

	<i>Houses</i>	<i>Cameraman</i>	<i>Pepper</i>	<i>Mandrill</i>	<i>Barbara</i>	<i>Fish</i>	<i>Gate</i>
bez šuma	31,75%	22,71%	13,36%	30,54%	21,82%	21,88%	18,96%
granularni	26,77%	13,64%	10,65%	28,34%	18,63%	7,92%	3,78%
Gaussov	19,95%	10,49%	7,85%	23,83%	14,12%	5,18%	2,37%
s&p	21,13%	11,38%	7,03%	22,62%	13,47%	4,97%	3,30%
Poissonov	27,79%	14,33%	10,84%	28,77%	18,58%	7,67%	4,36%

Tablica 1. SSIM vrijednosti za primjenu Sobel operatora na slike

Izvor: Izradio autor

4.2.2. Rezultati primjene Prewitt operatora

Slika 28 prikazuje kod koji je korišten za primjenu Prewitt operatora na sliku. S obzirom na nedostatak implementacije Prewitt operatora u nekoj od popularnih Python biblioteka za obradu slike, bilo je potrebno napraviti implementaciju svih koraka. Može se primijetiti sličnost s implementacijom Sobela uz dodatak da je Prewitt kod morao

specificirati svojstva kernela. Koristi se `filter2D` metoda OpenCV biblioteke za primjenu operatora te se krajnje slike zbrajaju kako bi se dobila završna slika.

```
def apply_Prewitt(image):
    kernel_x = np.array([[1,1,1],[0,0,0],[-1,-1,-1]])
    kernel_y = np.array([[-1,0,1],[-1,0,1],[-1,0,1]])

    img_prewitt_x = cv2.filter2D(image, -1, kernel_x)
    img_prewitt_y = cv2.filter2D(image, -1, kernel_y)

    return img_prewitt_x + img_prewitt_y
```

Slika 28. Python kod za Prewitt operator
Izvor: Izradio autor

Tablica 2 prikazuje usporedbu rezultata između različitih oblika šuma i slika nad kojima je primijenjen Prewitt operator. Sveukupno su dobiveni rezultati slični onima dobivenim korištenjem Sobel operatora. Prewitt pristup je bio znatno uspješniji kod nekih slika bez šuma, ali se ta razlika drastično smanjila nakon uvođenja šuma.

	<i>Houses</i>	<i>Cameraman</i>	<i>Pepper</i>	<i>Mandrill</i>	<i>Barbara</i>	<i>Fish</i>	<i>Gate</i>
bez šuma	28,48%	35,97%	19,20%	20,01%	21,67%	29,65%	19,02%
granularni	24,08%	15,43%	12,41%	17,83%	16,02%	8,98%	4,46%
Gaussov	21,02%	12,99%	7,47%	16,40%	11,55%	4,33%	2,39%
s&p	20,75%	13,50%	6,92%	15,43%	11,05%	4,22%	2,80%
Poissonov	24,05%	15,81%	12,35%	18,59%	15,37%	7,94%	5,55%

Tablica 2. SSIM vrijednosti za primjenu Prewitt operatora na slike
Izvor: Izradio autor

4.2.3. Rezultati primjene Laplace operatora

Slika 29 prikazuje kod korišten za primjenu Laplace operatora. Drugi argument metode iz OpenCV biblioteke predstavlja preciznost izlaznih podataka koja je ovdje definirana kao 64-bitna vrijednost s pomičnim zarezom.

```
def apply_Laplacian(image):
    return cv2.Laplacian(image, cv2.CV_64F)
```

Slika 29. Python kod za Laplace operator
Izvor: Izradio autor

Tablica 3 prikazuje usporedbu rezultata između različitih oblika šuma i slika nad kojima je primijenjen Laplace operator. Dok su rezultati slika bez šuma uspješniji od prethodnih operatora, većina slika na kojima je prisutan šum ostvaruju lošije rezultate

od prethodnih pristupa što je u skladu s literaturom. Iznenadjući rezultat predstavlja *Fish* slika bez prisustva šuma čiji postotak nadilazi sve dosad dobivene vrijednosti.

	<i>Houses</i>	<i>Cameraman</i>	<i>Pepper</i>	<i>Mandrill</i>	<i>Barbara</i>	<i>Fish</i>	<i>Gate</i>
bez šuma	12,06%	39,19%	27,14%	6,84%	25,23%	58,89%	22,70%
granularni	3,23%	5,50%	11,97%	1,77%	9,45%	10,57%	1,65%
Gaussov	0,06%	2,08%	2,22%	0,76%	1,77%	1,64%	0,85%
s&p	3,06%	8,75%	6,06%	2,17%	3,83%	8,00%	5,08%
Poissonov	2,94%	5,41%	10,89%	2,14%	7,38%	7,49%	0,80%

Tablica 3. SSIM vrijednosti za primjenu Laplace operatora na slike
Izvor: Izradio autor

4.2.4. Rezultati primjene Canny algoritma

Slika 30 prikazuje kod korišten za primjenu Canny algoritma. Algoritam očekuje specificiranje donje i gornje granice za potrebe histereze. U slučaju koda te su granice postavljene na njihove zadane vrijednosti koje korisnik po potrebi može namjestiti.

```
def apply_Canny(image low=50, high=100):
    return cv2.Canny(image, low, high)
```

Slika 30. Python kod za Canny algoritam
Izvor: Izradio autor

Tablica 4 prikazuje usporedbu rezultata između različitih oblika šuma i slika nad kojima je primijenjen Canny operator. Rezultati predstavljaju najuspješnija dostignuća s obzirom na preciznost algoritma i njegovih povratnih rubova.


	<i>Houses</i>	<i>Cameraman</i>	<i>Pepper</i>	<i>Mandrill</i>	<i>Barbara</i>	<i>Fish</i>	<i>Gate</i>
bez šuma	77,60%	68,27%	73,06%	66,32%	76,34%	73,66%	74,93%
granularni	44,50%	22,01%	34,39%	43,77%	45,35%	35,20%	8,97%
Gaussov	27,16%	12,98%	6,35%	31,02%	15,97%	4,02%	1,44%
s&p	36,37%	18,31%	7,00%	32,61%	17,91%	4,75%	2,96%
Poissonov	44,15%	20,34%	33,68%	45,11%	44,98%	34,63%	18,52%

Tablica 4. SSIM vrijednosti za primjenu Canny operatora na slike
Izvor: Izradio autor

4.3. Usporedba rezultata među slikama

Svi algoritmi prepoznavanja rubova imaju najviše poteškoća s Gaussovim šumom nakon kojeg slijedi s&p šum. Canny algoritam značajno nadilazi rezultate svih ostalih.


Na Slici 31 može se vidjeti rezultat primjene Sobel operatora na *Houses* sliku kod prisustva različitih vrsta šuma.



Slika 31. Rezultati primjene Sobel operatora na *Houses* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor


Na Slici 32 može se vidjeti rezultat primjene Prewitt operatora na *Houses* sliku kod prisustva različitih vrsta šuma.



Slika 32. Rezultati primjene Prewitt operatora na *Houses* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor


Na Slici 33 može se vidjeti rezultat primjene Laplace operatora na *Houses* sliku kod prisustva različitih vrsta šuma.



Slika 33. Rezultati primjene Laplace operatora na *Houses* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor

Na Slici 34 može se vidjeti rezultat primjene Canny algoritma na *Houses* sliku kod prisustva različitih vrsta šuma.



Slika 34. Rezultati primjene Canny algoritma na *Houses* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor

Tablica 5 prikazuje usporedbu rezultata primjene pojedinih operatora za detekciju rubova na sliku *Houses* uz različite vrste šuma.

	bez šuma	granularni	Gaussov	s&p	Poissonov
Sobel	31,75%	26,77%	19,95%	21,13%	27,79%
Prewitt	28,48%	24,08%	21,02%	20,75%	24,05%
Laplace	12,06%	3,23%	0,06%	3,06%	2,94%
Canny	77,60%	44,50%	27,16%	36,37%	44,15%

Tablica 5. SSIM vrijednosti za primjenu operatora za detekciju rubova na sliku *Houses* uz različite vrste šuma


Izvor: Izradio autor

Iz slikovnih rezultata *Houses* slike vidljivo je da najjasnije rubove, čak i uz prisutnost šuma, daje Prewitt operator. Njegove dobivene slike usporedive su sa Sobel operatorom čiji je izlaz svjetlijih tonova što povećava uočljivost rubova, ali i šuma.

Tonovi na slikama dobivenim Laplace operatorom su prigušeniji i teško je raspoznati rubove koji su ovdje vrlo tanki u prisustvu šuma. Uočavanje rubova na izlaznim slikama Canny algoritma s prisustvom šuma je veoma zahtjevno neovisno o vrsti šuma. Šumovi koji najviše smetaju kod raspoznavanja rubova na *Houses* slici su Gaussov i s&p.

Iz rezultata dobivenih SSIM metrikom nad *Houses* slikom može se primijetiti kako Canny algoritam daje daleko najbolje rezultate, Sobel i Prewitt imaju sličnu uspješnost dok je Laplace operator uvjerljivo posljednji. Najviše poteškoća, kao što je vidljivo i na slikama, stvaraju Gaussov i s&p šumovi.


Na Slici 35 može se vidjeti rezultat primjene Sobel operatora na *Cameraman* sliku kod prisustva različitih vrsta šuma.



Slika 35. Rezultati primjene Sobel operatora na *Cameraman* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodatnim granularnim šumom. c) Slika s dodatnim Gausovim šumom. d) Slika s dodatnim s&p šumom. e) Slika s dodatnim Poissonovim šumom.

Izvor: Izradio autor


Na Slici 36 može se vidjeti rezultat primjene Prewitt operatora na *Cameraman* sliku kod prisustva različitih vrsta šuma.



Slika 36. Rezultati primjene Prewitt operatora na *Cameraman* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor


Na Slici 37 može se vidjeti rezultat primjene Laplace operatora na *Cameraman* sliku kod prisustva različitih vrsta šuma.



Slika 37. Rezultati primjene Laplace operatora na *Cameraman* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor

Na Slici 38 može se vidjeti rezultat primjene Canny algoritma na *Cameraman* sliku kod prisustva različitih vrsta šuma.



Slika 38. Rezultati primjene Canny algoritma na *Cameraman* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor

Tablica 6 prikazuje usporedbu rezultata primjene pojedinih operatora za detekciju rubova na sliku *Cameraman* uz različite vrste šuma.

	bez šuma	granularni	Gaussov	s&p	Poissonov
Sobel	22,71%	13,64%	10,49%	11,38%	14,33%
Prewitt	35,79%	15,43%	12,99%	13,50%	15,81%
Laplace	39,19%	5,50%	2,08%	8,75%	5,41%
Canny	68,27%	22,01%	12,98%	18,31%	20,34%

Tablica 6. SSIM vrijednosti za primjenu operatora za detekciju rubova na sliku *Cameraman* uz različite vrste šuma


Izvor: Izradio autor

Iz slikovnih rezultata *Cameraman* slike vidljivo je da najjasnije rubove, čak i uz prisutnost šuma, daje Prewitt operator. Kako je uočeno i na *Houses* slici, njegovi su rezultati usporedivi sa Sobel operatorom kod čijih je vidljivost rubova otežana njegovim

povišenim tonovima. Laplace operator i u ovom slučaju generira tanke rubove, ali uz nusprodukt transfera šuma iz ulazne slike. Uočavanje rubova na izlaznim slikama Canny algoritma je i u ovom slučaju zahtjevno neovisno o vrsti šuma. Šumovi koji najviše smetaju kod raspoznavanja rubova na *Cameraman* slici su ponovno Gaussov i s&p.

Iz rezultata dobivenih SSIM metrikom nad *Cameraman* slikom može se primijetiti kako Canny algoritam daje daleko najbolje rezultate, Sobel i Prewitt imaju sličnu uspješnost iako je prednost Prewitt operatora na ovoj slici konstantna dok je Laplace operator uvjerljivo posljednji. Najviše poteškoća, kao što je vidljivo i na slikama, stvaraju Gaussov i s&p šumovi.


Na Slici 39 može se vidjeti rezultat primjene Sobel operatora na *Pepper* sliku kod prisustva različitih vrsta šuma.



Slika 39. Rezultati primjene Sobel operatora na *Pepper* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor


Na Slici 40 može se vidjeti rezultat primjene Prewitt operatora na *Pepper* sliku kod prisustva različitih vrsta šuma.



Slika 40. Rezultati primjene Prewitt operatora na *Pepper* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor


Na Slici 41 može se vidjeti rezultat primjene Laplace operatora na *Pepper* sliku kod prisustva različitih vrsta šuma.



Slika 41. Rezultati primjene Laplace operatora na *Pepper* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor

Na Slici 42 može se vidjeti rezultat primjene Canny algoritma na *Pepper* sliku kod prisustva različitih vrsta šuma.



Slika 42. Rezultati primjene Canny algoritma na *Pepper* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor

Tablica 7 prikazuje usporedbu rezultata primjene pojedinih operatora za detekciju rubova na sliku *Pepper* uz različite vrste šuma.

	bez šuma	granularni	Gaussov	s&p	Poissonov
Sobel	13,36%	10,65%	7,85%	7,03%	10,84%
Prewitt	19,20%	12,41%	7,47%	6,92%	12,35%
Laplace	27,14%	11,97%	2,22%	6,06%	10,89%
Canny	73,06%	34,39%	6,35%	7,00%	33,68%

Tablica 7. SSIM vrijednosti za primjenu operatora za detekciju rubova na sliku *Pepper* uz različite vrste šuma


Izvor: Izradio autor

Rezultati prethodnih slika se nastavljaju i na *Pepper* slici gdje Prewitt operator vodi, Sobel operator generira sličnu sliku Prewitt rezultatu uz veće poteškoće sa šumom i Canny algoritam generira teško raspoznatljive rubove kod prisutnosti šuma. Laplace

operator iz ove slike generira jako mračan rezultat koji stvara još veće poteškoće u vidljivosti rubova nego kod prethodnih slika. Šumovi sa najvećim utjecajem na rezultat su i dalje Gaussov i s&p koji na *Pepper* slici imaju naročit negativan utjecaj na Laplace operator.

Iz rezultata dobivenih SSIM metrikom nad *Pepper* slikom može se primijetiti kako Canny algoritam ovdje ne daje najbolje rezultate za svaki od šumova i Sobel i Prewitt operatori ostvaruju sličnu uspješnost kod Gaussovog i s&p šuma. Laplace operator i ovdje ostvaruje najgore rezultate, naročito uz prisutnost Gaussovog šuma. Najviše poteškoća, kao što je vidljivo i na slikama, stvaraju Gaussov i s&p šumovi.


Na Slici 43 može se vidjeti rezultat primjene Sobel operatora na *Mandrill* sliku kod prisustva različitih vrsta šuma.



Slika 43. Rezultati primjene Sobel operatora na *Mandrill* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor


Na Slici 44 može se vidjeti rezultat primjene Prewitt operatora na *Mandrill* sliku kod prisustva različitih vrsta šuma.



Slika 44. Rezultati primjene Prewitt operatora na *Mandrill* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor


Na Slici 45 može se vidjeti rezultat primjene Laplace operatora na *Mandrill* sliku kod prisustva različitih vrsta šuma.



Slika 45. Rezultati primjene Laplace operatora na *Mandrill* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor

Na Slici 46 može se vidjeti rezultat primjene Canny algoritma na *Mandrill* sliku kod prisustva različitih vrsta šuma.



Slika 46. Rezultati primjene Canny algoritma na *Mandrill* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor

Tablica 8 prikazuje usporedbu rezultata primjene pojedinih operatora za detekciju rubova na sliku *Mandrill* uz različite vrste šuma.

	bez šuma	granularni	Gaussov	s&p	Poissonov
Sobel	30,54%	28,34%	23,83%	22,62%	28,77%
Prewitt	20,01%	17,83%	16,40%	15,43%	18,59%
Laplace	6,84%	1,77%	0,76%	2,17%	2,14%
Canny	66,32%	43,77%	31,02%	32,61%	45,11%

Tablica 8. SSIM vrijednosti za primjenu operatora za detekciju rubova na sliku *Mandrill* uz različite vrste šuma


Izvor: Izradio autor

Na slikovnim rezultatima *Mandrill* slike uočljivi su rezultati slični prethodnim slikama. Prewitt operator daje najjasnije rubove dok Canny algoritam ovdje ostvaruje jako lošu

vidljivost bez obzira na prisutnost šuma. Šumovi s najvećim utjecajem na rezultat su Gaussov i s&p.

Iz rezultata dobivenih SSIM metrikom nad *Mandrill* slikom može se primijetiti kako Canny algoritam i ovdje daje najbolje rezultate. Sobel i Prewitt operatori ostvaruju sličnu uspješnost uz uvjerljivo vodstvo Sobel operatora. Laplace operator i ovdje ostvaruje najgore rezultate. Najviše poteškoća stvaraju Gaussov i s&p šumovi.


Na Slici 47 može se vidjeti rezultat primjene Sobel operatora na *Barbara* sliku kod prisustva različitih vrsta šuma.



Slika 47. Rezultati primjene Sobel operatora na *Barbara* sliku kod prisustva različitih oblika šuma: a) izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor


Na Slici 48 može se vidjeti rezultat primjene Prewitt operatora na *Barbara* sliku kod prisustva različitih vrsta šuma.



Slika 48. Rezultati primjene Prewitt operatora na *Barbara* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor


Na Slici 49 može se vidjeti rezultat primjene Laplace operatora na *Barbara* sliku kod prisustva različitih vrsta šuma.



Slika 49. Rezultati primjene Laplace operatora na *Barbara* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor

Na Slici 50 može se vidjeti rezultat primjene Canny algoritma na *Barbara* sliku kod prisustva različitih vrsta šuma.



Slika 50. Rezultati primjene Canny algoritma na *Barbara* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor

Tablica 9 prikazuje usporedbu rezultata primjene pojedinih operatora za detekciju rubova na sliku *Barbara* uz različite vrste šuma.

	bez šuma	granularni	Gaussov	s&p	Poissonov
Sobel	21,82%	18,63%	14,12%	13,47%	18,58%
Prewitt	21,67%	16,02%	11,55%	11,05%	15,37%
Laplace	25,23%	9,45%	1,77%	3,83%	7,38%
Canny	76,34%	45,35%	15,97%	17,91%	44,98%

Tablica 9. SSIM vrijednosti za primjenu operatora za detekciju rubova na sliku *Barbara* uz različite vrste šuma


Izvor: Izradio autor

Na slikovnim rezultatima *Barbara* slike uočljivi su rezultati slični prethodnim slikama. Prewitt operator daje najjasnije rubove dok Canny algoritam ovdje ostvaruje jako lošu vidljivost bez obzira na prisutnost šuma. Laplace operator, kao i kod *Pepper* slike, generira vrlo mračnu sliku. Šumovi s najvećim utjecajem na rezultat su Gaussov i s&p.

Iz rezultata dobivenih SSIM metrikom nad *Barbara* slikom može se primijetiti kako Canny algoritam i ovdje daje najbolje rezultate. Sobel i Prewitt operatori ostvaruju

sličnu uspješnost uz vodstvo Sobel operatora. Laplace operator i ovdje ostvaruje najgore rezultate. Najviše poteškoća stvaraju Gaussov i s&p šumovi.


Na Slici 51 može se vidjeti rezultat primjene Sobel operatora na *Fish* sliku kod prisustva različitih vrsta šuma.



Slika 51. Rezultati primjene Sobel operatora na *Fish* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor


Na Slici 52 može se vidjeti rezultat primjene Prewitt operatora na *Fish* sliku kod prisustva različitih vrsta šuma.



Slika 52. Rezultati primjene Prewitt operatora na *Fish* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor


Na Slici 53 može se vidjeti rezultat primjene Laplace operatora na *Fish* sliku kod prisustva različitih vrsta šuma.



Slika 53. Rezultati primjene Laplace operatora na *Fish* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor

Na Slici 54 može se vidjeti rezultat primjene Canny algoritma na *Fish* sliku kod prisustva različitih vrsta šuma.



Slika 54. Rezultati primjene Canny algoritma na *Fish* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor

Tablica 10 prikazuje usporedbu rezultata primjene pojedinih operatora za detekciju rubova na sliku *Fish* uz različite vrste šuma.

	bez šuma	granularni	Gaussov	s&p	Poissonov
Sobel	21,88%	7,92%	5,18%	4,97%	7,67%
Prewitt	29,65%	8,98%	4,33%	4,22%	7,94%
Laplace	58,89%	10,57%	1,64%	8,00%	7,49%
Canny	73,66%	35,20%	4,02%	4,75%	34,63%


Tablica 10. SSIM vrijednosti za primjenu operatora za detekciju rubova na sliku *Fish* uz različite vrste šuma

Izvor: Izradio autor

Na slikovnim rezultatima *Fish* slike uočljivi su rezultati slični prethodnim slikama. Prewitt operator daje najjasnije rubove dok Canny algoritam ovdje ostvaruje jako lošu vidljivost bez obzira na prisutnost šuma. Laplace operator, kao i kod *Pepper* i *Barbara* slika, generira vrlo mračnu sliku. Šumovi s najvećim utjecajem na rezultat su Gaussov i s&p.

Iz rezultata dobivenih SSIM metrikom nad *Fish* slikom može se primijetiti kako Canny algoritam ni ovdje ne daje uvjerljivo najbolje rezultate i dijeli uspješnost sa Sobel i Prewitt operatorima koji ostvaruju slične rezultate kod prisutnosti Gaussovog šuma dok Laplace operator ovdje ostvaruje iznenađujuće rezultate uz prisutnost s&p šuma što nije vidljivo na slikama. Najviše poteškoća stvaraju Gaussov i s&p šumovi.


Na Slici 55 može se vidjeti rezultat primjene Sobel operatora na *Gate* sliku kod prisustva različitih vrsta šuma.



Slika 55. Rezultati primjene Sobel operatora na *Gate* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor


Na Slici 56 može se vidjeti rezultat primjene Prewitt operatora na *Gate* sliku kod prisustva različitih vrsta šuma.



Slika 56. Rezultati primjene Prewitt operatora na *Gate* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor


Na Slici 57 može se vidjeti rezultat primjene Laplace operatora na *Gate* sliku kod prisustva različitih vrsta šuma.



Slika 57. Rezultati primjene Laplace operatora na Gate sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor

Na Slici 58 može se vidjeti rezultat primjene Canny algoritma na Gate sliku kod prisustva različitih vrsta šuma.



Slika 58. Rezultati primjene Canny algoritma na *Gate* sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.

Izvor: Izradio autor

Tablica 11 prikazuje usporedbu rezultata primjene pojedinih operatora za detekciju rubova na sliku *Gate* uz različite vrste šuma.

	bez šuma	granularni	Gaussov	s&p	Poissonov
Sobel	18,96%	3,78%	2,37%	3,30%	4,36%
Prewitt	19,02%	4,46%	2,39%	2,80%	5,55%
Laplace	22,70%	1,65%	0,85%	5,08%	0,80%
Canny	74,93%	8,97%	1,44%	2,96%	18,52%

Tablica 11. SSIM vrijednosti za primjenu operatora za detekciju rubova na sliku *Gate* uz različite vrste šuma

Izvor: Izradio autor

Na slikovnim rezultatima *Gate* slike uočljivi su rezultati slični prethodnim slikama uz iznimku da Sobel i Prewitt operatori generiraju jako slične rezultate. Canny algoritam i ovdje ostvaruje jako lošu vidljivost bez obzira na prisutnost šuma. Laplace operator, kao što je bilo i prethodno vidljivo, generira vrlo mračnu sliku. Šumovi s najvećim utjecajem na rezultat su Gaussov i s&p koji na ovoj slici drastično utječu i na Sobel i Prewitt operator.

Iz rezultata dobivenih SSIM metrikom nad *Gate* slikom može se primijetiti sličnost s rezultatima *Fish* slike. Canny algoritam ostvaruje uvjerljivo bolje rezultate kod granularnog i Poissonovog šuma, Sobel i Prewitt operatori ostvaruju sličnu uspješnost kod Gaussovog šuma dok je Laplace operator najlošiji uz iznimku s&p šuma gdje ostvaruje najbolje rezultate. Najviše poteškoća stvaraju Gaussov i s&p šumovi.

5. Zaključak

Ovaj se rad bavio problematikom pronalaženja rubova na slikama koristeći različite metode pronalaženja rubova u uvjetima različitih vrsta šuma. Opisan je način kako rubovi na slikama nastaju te kojih oblika mogu biti. Nakon toga je slijedilo opisivanje matematičkih metoda koje se koriste pri detekciji rubova te su opisani načini njihove implementacije unutar Sobel, Prewitt i Laplace operatora te Canny algoritma. U sljedećem koraku su opisane slike nad kojima će se rubovi pretraživati te odabrani šumovi koji će na te iste slike biti primijenjeni gdje su za testiranje odabrani granularni, Gaussov, impulsni i Poissonov šum. Opisani su načini implementacije metoda u kodu te su uspješnosti rezultata prikazane slikovno i tablično u postotnom obliku korištenjem SSIM metrike te su dobiveni rezultati komentirani.

Analizom rezultata je utvrđeno da Canny algoritam najuspješnije pronalazi rubove po danoj metrici iako algoritam generira slike kod kojih je teško uočiti rubove, naročito uz prisutnost šuma. Sobel i Prewitt operatori se nalaze na sljedećem mjestu uspješnosti. Dolaze do sličnih rezultata gdje svaki ima svoje prednosti i nedostatke ovisno o slici i šumu na koji nailaze. S vizualne strane ovi operatori generiraju najkvalitetnije rubove gdje Prewitt operator ima prednost zbog njegovih slika tamnijih tonova što kao posljedicu ima uklanjanje šuma dok Sobel operator generira svjetlije slike na kojima su rubovi deblji, ali je također šum znatno vidljiviji. Laplace operator, unatoč relativnoj konkurentnosti s prethodna dva operatora na slikama bez šuma, nailazi na najviše problema na slikama koje sadrže bilo kakav oblik šuma što je posljedica njegovog pristupa korištenja druge derivacije. Loši rezultati metrike se odražavaju i na vizualni aspekt gdje Laplace operator ponekad generira sliku veoma tamnih tonova što uz prisutnost šuma čini raspoznavanje rubova veoma zahtjevnim. Testna slika s najlošijim rezultatima je *Gate* koja pripada skupu podvodnih slika što je vjerojatno produkt njezinog nastanka u realnim uvjetima. Ova slika je stvorila probleme čak i kod vizualizacije Sobel i Prewitt rezultata generiranjem slika veoma tamnih tonova. Ostale slike su proizvele prilično slične rezultate među kojima dominira *Houses* slika s obzirom na njezine oštre rubove.

Literatura

- Forsyth, David A, i Jean Ponce. 2011. *Computer Vision: A Modern Approach*. New Jersey: Pearson.
- Gonzalez, Rafael C., i Richard E. Woods. 2008. *Digital Image Processing*. Pearson.
- Ivković, Ratko, Ivana Milošević, Branimir Jakšić, Petar Spavelić, i Mirko Milošević. 2018. »Definisanje karakteristika snow and rain šuma digitalne slike metodom parcijalnog filtriranja.« *SINTEZA*. Beograd: Singinudum University. 242-247.
- Jähne, Bernd. 2005. *Digital Image Processing*. Heidelberg: Springer.
- Lakshmi, K. T. S., i R. Anil Kumar. 2022. »An Analysis of Image Segmentation Methods.« *Advanced Production and Industrial Engineering* 635-340.
- MathWorks. 2024. *Help Center: SSIM*. Pokušaj pristupa 4. rujan 2024. <https://www.mathworks.com/help/images/ref/ssim.html>.
- Microsoft. 2020. *Win32 apps: Gaussian blur effect*. 12. prosinac. Pokušaj pristupa 24. lipanj 2024. <https://learn.microsoft.com/en-us/windows/win32/direct2d/gaussian-blur>.
- Nayar, Shree. 2021. *YouTube: Edge Detection Using Laplacian | Edge Detection*. 3. ožujak. Pokušaj pristupa 5. srpanj 2024. <https://www.youtube.com/watch?v=uNP6ZwQ3r6A>.
- . 2021. *YouTube: What is an Edge? | Edge Detection*. 3. ožujak. Pokušaj pristupa 1. srpanj 2024. https://www.youtube.com/watch?v=G8yp6f9V_6c.
- OpenCV. 2024. *Tutorials: Laplace Operator*. Pokušaj pristupa 26. lipanj 2024. https://docs.opencv.org/3.4/d5/db5/tutorial_laplace_operator.html.
- Pound, Mike. 2015. *YouTube - Finding the Edges (Sobel Operator) - Computerphile*. 4. studeni. Pokušaj pristupa 10. srpanj 2024. <https://www.youtube.com/watch?v=uihBwtPIBxM>.
- . 2015. *YouTube: Canny Edge Detector - Computerphile*. 11. studeni. Pokušaj pristupa 10. srpanj 2024. <https://www.youtube.com/watch?v=sRFM5IEqR2w>.
- Russ, John C. 2006. *The Image Processing Handbook*. Boca Raton: CRC Press.
- Singh, Prabhishkek, i Raj Shree. 2016. »Analysis and effects of speckle noise in SAR images.« *International Conference on Advances in Computing, Communication, & Automation (ICACCA) (Fall)*. Bareilly, India: IEEE. 1-5.
- Szelinski, Richard. 2022. *Computer Vision: Algorithms and Applications*. Springer.
- Walt, Stefan van der. 2024. *Github: Scikit-image*. 16. siječanj. Pokušaj pristupa 4. rujan 2024. <https://github.com/scikit-image/scikit-image/blob/v0.24.0/skimage/util/noise.py#L39-L233>.

Popis slika

Slika 1. Fenomeni stvaranja rubova	3
Slika 2. Nagli rub	4
Slika 3. Krovni rub	5
Slika 4. Rampni rub	5
Slika 5. Karakteristike derivacija rampnog ruba	6
Slika 6. Utjecaj šuma na derivacije rampnog ruba	8
Slika 7. Roberts operator.....	10
Slika 8. Sobel operator	11
Slika 9. Primjena Sobel operatora	12
Slika 10. Primjena Gaussovog zamućenja	13
Slika 11. Prewitt operator	13
Slika 12. Primjena Prewitt operatora	13
Slika 13. Laplace operator.....	14
Slika 14. Primjena Gaussovog zamućenja za potrebe primjene Laplace	14
Slika 15. Primjena Laplace operatora.....	15
Slika 16. Metoda histereznog praga.....	16
Slika 17. Rezultati primjene različitih vrsta šuma na <i>Houses</i> sliku: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	20
Slika 18. Rezultati primjene različitih vrsta šuma na <i>Cameraman</i> sliku: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.....	21
Slika 19. Rezultati primjene različitih vrsta šuma na <i>Pepper</i> sliku: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	22
Slika 20. Rezultati primjene različitih vrsta šuma na <i>Mandrill</i> sliku: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	23
Slika 21. Rezultati primjene različitih vrsta šuma na <i>Barbara</i> sliku: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	24
Slika 22. Rezultati primjene različitih vrsta šuma na <i>Fish</i> sliku: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	25
Slika 23. Rezultati primjene različitih vrsta šuma na <i>Gate</i> sliku: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gausovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	26
Slika 24. Slike rubova dobivene podešenim Canny algoritmom: a) <i>Houses</i> slika. b) <i>Cameraman</i> slika. c) <i>Pepper</i> slika. d) <i>Mandrill</i> slika. e) <i>Barbara</i> slika. f) <i>Fish</i> slika. g) <i>Gate</i> slika.	29
Slika 25. Python kod za Sobel operator	30
Slika 26. Primjena Sobel operatora na <i>Houses</i> sliku.....	30
Slika 27. Usporedba debljine rubova između Sobel i Laplace operatora	31
Slika 28. Python kod za Prewitt operator.....	32
Slika 29. Python kod za Laplace operator	32

Slika 30. Python kod za Canny algoritam.....	33
Slika 31. Rezultati primjene Sobel operatora na <i>Houses</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	34
Slika 32. Rezultati primjene Prewitt operatora na <i>Houses</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	35
Slika 33. Rezultati primjene Laplace operatora na <i>Houses</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	36
Slika 34. Rezultati primjene Canny algoritma na <i>Houses</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	37
Slika 35. Rezultati primjene Sobel operatora na <i>Cameraman</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	38
Slika 36. Rezultati primjene Prewitt operatora na <i>Cameraman</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	39
Slika 37. Rezultati primjene Laplace operatora na <i>Cameraman</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	40
Slika 38. Rezultati primjene Canny algoritma na <i>Cameraman</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	41
Slika 39. Rezultati primjene Sobel operatora na <i>Pepper</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	42
Slika 40. Rezultati primjene Prewitt operatora na <i>Pepper</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	43
Slika 41. Rezultati primjene Laplace operatora na <i>Pepper</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	44

Slika 42. Rezultati primjene Canny algoritma na <i>Pepper</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	45
Slika 43. Rezultati primjene Sobel operatora na <i>Mandrill</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	46
Slika 44. Rezultati primjene Prewitt operatora na <i>Mandrill</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	47
Slika 45. Rezultati primjene Laplace operatora na <i>Mandrill</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	48
Slika 46. Rezultati primjene Canny algoritma na <i>Mandrill</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	49
Slika 47. Rezultati primjene Sobel operatora na <i>Barbara</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	50
Slika 48. Rezultati primjene Prewitt operatora na <i>Barbara</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	51
Slika 49. Rezultati primjene Laplace operatora na <i>Barbara</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	52
Slika 50. Rezultati primjene Canny algoritma na <i>Barbara</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	53
Slika 51. Rezultati primjene Sobel operatora na <i>Fish</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	54
Slika 52. Rezultati primjene Prewitt operatora na <i>Fish</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	55
Slika 53. Rezultati primjene Laplace operatora na <i>Fish</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s	

dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	55
Slika 54. Rezultati primjene Canny algoritma na <i>Fish</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	56
Slika 55. Rezultati primjene Sobel operatora na <i>Gate</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	57
Slika 56. Rezultati primjene Prewitt operatora na <i>Gate</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	58
Slika 57. Rezultati primjene Laplace operatora na <i>Gate</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	59
Slika 58. Rezultati primjene Canny algoritma na <i>Gate</i> sliku kod prisustva različitih oblika šuma: a) Izvorna slika. b) Slika s dodanim granularnim šumom. c) Slika s dodanim Gaussovim šumom. d) Slika s dodanim s&p šumom. e) Slika s dodanim Poissonovim šumom.	60

Popis tablica

Tablica 1. SSIM vrijednosti za primjenu Sobel operatora na slike	31
Tablica 2. SSIM vrijednosti za primjenu Prewitt operatora na slike	32
Tablica 3. SSIM vrijednosti za primjenu Laplace operatora na slike	33
Tablica 4. SSIM vrijednosti za primjenu Canny operatora na slike	33
Tablica 5. SSIM vrijednosti za primjenu operatora za detekciju rubova na sliku <i>Houses</i> uz različite vrste šuma	37
Tablica 6. SSIM vrijednosti za primjenu operatora za detekciju rubova na sliku <i>Cameraman</i> uz različite vrste šuma	41
Tablica 7. SSIM vrijednosti za primjenu operatora za detekciju rubova na sliku <i>Pepper</i> uz različite vrste šuma	45
Tablica 8. SSIM vrijednosti za primjenu operatora za detekciju rubova na sliku <i>Mandrill</i> uz različite vrste šuma	49
Tablica 9. SSIM vrijednosti za primjenu operatora za detekciju rubova na sliku <i>Barbara</i> uz različite vrste šuma	53
Tablica 10. SSIM vrijednosti za primjenu operatora za detekciju rubova na sliku <i>Fish</i> uz različite vrste šuma	56
Tablica 11. SSIM vrijednosti za primjenu operatora za detekciju rubova na sliku <i>Gate</i> uz različite vrste šuma	60

Sažetak

Ovaj se rad bavi problematikom usporedbe odabranih metoda za detekciju rubova na digitalnim slikama u uvjetima različitih vrsta šuma. Izložena je motivacija za istraživanjem detekcije rubova i predstavljena šira slika u kojoj se problematika detekcije rubova nalazi. Opisan je način kako rubovi na slikama nastaju, kojih oblika mogu biti te svojstva njihovih prvih i drugih derivacija. Opisane su matematičke metode koje se koriste pri detekciji rubova i načini njihove implementacije unutar Sobel, Prewitt i Laplace operatora te Canny algoritma. Opisane su slike nad kojima su primijenjene metode za detekciju rubova u njihovom izvornom obliku i utjecaj odabranih vrsta šuma na iste od kojih su za testiranje odabrani granularni, Gaussov, impulsni i Poissonov šum. Opisani su načini implementacije metoda u kodu te su uspješnosti rezultata prikazane slikovno i tablično u postotnom obliku korištenjem SSIM metrike. Rezultati su pokazali da je po odabranoj metrici najuspješniji Canny algoritam kojeg slijede Sobel i Prewitt operatori sa sličnim rezultatima dok se Laplace operator pokazao kao najlošiji. S vizualnog aspekta najuspješnije su rezultate generirali Sobel i Prewitt operator, među kojima je prednost imao Prewitt operator. Laplace operator je dao dobre rezultate kod slika bez šuma, ali je kod prisutnosti šuma imao znatnih poteškoća. Canny algoritam je generirao vizualno najmanje poželjne slike u većini testiranih uvjeta.

Ključne riječi: detekcija rubova, Canny algoritam, Sobel operator, Prewitt operator, Laplace operator

Abstract

This paper deals with the issue of comparing selected methods for edge detection in digital images under conditions of different types of noise. The motivation for edge detection research is introduced and the broader context in which the problem of edge detection is situated is presented. The process by which edges in images are formed, their potential shapes, and the properties of their first and second derivatives are described. The mathematical methods used for edge detection, and their implementation through the Sobel, Prewitt and Laplace operators and the Canny algorithm are outlined. The images on which the edge detection methods were applied in their original form and the impact of the selected types of noise on them are described, of which speckle, Gaussian, salt-and-pepper and Poisson noise were selected for testing. The methods' implementations in code are described, and the results are presented graphically and in tabular form in the percentage form using the SSIM metric. The results showed that, according to the chosen metric, the Canny algorithm was the most successful, followed by the Sobel and Prewitt operators with similar results, while the Laplace operator was found to be the least effective. From a visual aspect, the most successful results were generated by the Sobel and Prewitt operators, with the Prewitt operator having an advantage. The Laplace operator produced good results in noise-free images but faced significant difficulties in the presence of noise. The Canny algorithm generated the least visually appealing images in most of the tested conditions.

Keywords: edge detection, Canny algorithm, Sobel operator, Prewitt operator, Laplace operator