# Usporedba algoritama čvrstog i neizrazitog grupiranja podataka za segmentaciju slike

**Loina, Luka**

**Undergraduate thesis / Završni rad**

**2018**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj:* **Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek**

*Permanent link / Trajna poveznica:* https://urn.nsk.hr/urn:nbn:hr:200:188009

*Rights / Prava:* In copyright / Zaštićeno autorskim pravom.

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

*Repository / Repozitorij:*

Faculty of Electrical Engineering, Computer Science and Information Technology Osijek

zir.nsk.hr

Image not found or type unknown

**SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU**
**ELEKTROTEHNIČKI FAKULTET**

**Preddiplomski studij računarstva**

# Usporedba algoritama čvrstog i neizrazitog grupiranja podataka za segmentaciju slike

**Završni rad**

**Luka Loina**

**Osijek, 2018.**

FERIT
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

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

**Osijek, 21.09.2018.**

**Odboru za završne i diplomske ispite**

# Prijedlog ocjene završnog rada

| | |
|---|---|
| **Ime i prezime studenta:** | Luka Loina |
| **Studij, smjer:** | Preddiplomski sveučilišni studij Računarstvo |
| **Mat. br. studenta, godina upisa:** | R3418, 28.09.2017. |
| **OIB studenta:** | 51976472308 |
| **Mentor:** | Prof.dr.sc. Goran Martinović |
| **Sumentor:** | Dr. sc. Dražen Bajer |
| **Sumentor iz tvrtke:** | |
| **Naslov završnog rada:** | Usporedba algoritama čvrstog i neizrazitog grupiranja podataka za segmentaciju slike |
| **Znanstvena grana rada:** | **Umjetna inteligencija (zn. polje računarstvo)** |
| **Predložena ocjena završnog rada:** | Izvrstan (5) |
| **Kratko obrazloženje ocjene prema Kriterijima za ocjenjivanje završnih i diplomskih radova:** | Primjena znanja stečenih na fakultetu: 3 bod/boda<br>Postignuti rezultati u odnosu na složenost zadatka: 3 bod/boda<br>Jasnoća pismenog izražavanja: 3 bod/boda<br>Razina samostalnosti: 3 razina |
| **Datum prijedloga ocjene mentora:** | 21.09.2018. |
| **Datum potvrde ocjene Odbora:** | 26.09.2018. |

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

FERIT
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA
I INFORMACIJSKIH TEHNOLOGIJA **OSIJEK**

# IZJAVA O ORIGINALNOSTI RADA

**Osijek, 28.09.2018.**

| | |
|---|---|
| **Ime i prezime studenta:** | Luka Loina |
| **Studij**: | Preddiplomski sveučilišni studij Računarstvo |
| **Mat. br. studenta, godina upisa:** | R3418, 28.09.2017. |
| **Ephorus podudaranje [%]:** | 7 |

Ovom izjavom izjavljujem da je rad pod nazivom**: Usporedba algoritama čvrstog i neizrazitog grupiranja podataka za segmentaciju slike**

izrađen pod vodstvom mentora Prof.dr.sc. Goran Martinović

i sumentora Dr. sc. Dražen Bajer

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

Potpis studenta:

# SADRŽAJ

1. UVOD ..... 1

2. GRUPIRANJE PODATAKA I SEGMENTACIJA SLIKE ..... 2

2.1. Grupiranje podataka ..... 2

2.1.1. Algoritam k-means ..... 4

2.1.2. Algoritam fuzzy c-means ..... 6

2.2. Segmentacija slike ..... 7

2.2.1. Primjena segmentacije slike ..... 8

2.2.2. Grupiranje podataka za segmentaciju slike ..... 9

3. OSTVARENO PROGRAMSKO RJEŠENJE ..... 11

3.1. Način rada programskog rješenja ..... 11

3.2. Prikaz i način uporabe programskog rješenja ..... 12

4. EKSPERIMENTALNA ANALIZA ..... 14

4.1. Postavke eksperimenta ..... 15

4.2. Rezultati ..... 16

5. ZAKLJUČAK ..... 20

# 1. UVOD

Segmentacija slike postupak je podjele slike na homogene cjeline prema nekom svojstvu koji se provodi kako bi se istaknula neka bitna svojstva slike. Segmentacija slike ima mnoštvo raznovrsnih primjena. Kao primjer segmentacije slike može se navesti uporaba u medicini gdje se koristi za izdvajanje različitih tkiva sa slike ili uporaba u području računalnog vida gdje se koristi za izdvajanje objekata sa slike. Grupiranje je postupak razvrstavanja podataka u grupe na temelju sličnosti podataka. Za razliku od segmentacije slike, gdje se uspješnost postupka može mjeriti samo ukoliko je poznata konačna primjena segmentacije, uspješnost grupiranja može se mjeriti objektivno, tj. cilj grupiranja je napraviti takve grupe da je razlika između elemenata prema nekoj mjeri sličnosti u njima minimalna. Elementi se mogu grupirati čvrsto, pridruživanjem svakog elementa samo jednoj grupi ili neizrazito, pridruživanjem svakog elementa svakoj grupi u nekoj mjeri. Problem pronalaska idealnog rješenja problema grupiranja podataka nije moguće riješiti efikasno. Iz tog razloga nastali su efikasni algoritmi za grupiranje podataka, kao što su k-means i fuzzy c-means, koji ne jamče idealno grupiranje. Ipak, takvi algoritmi u pravilu daju dovoljno dobro rješenje problema grupiranja podataka. Jedan od mnoštva načina za segmentaciju slike je primjena algoritama za grupiranje podataka.

U poglavlju 2 ukratko su opisane segmentacija slike i grupiranje podataka. Posebna pažnja posvećena je algoritmima za grupiranje k-means i fuzzy c-means te njihovoj primjeni pri grupiranju elemenata digitalne slike. U poglavlju 3 opisan je način rada programskog rješenja napravljenog za potrebe ovoga rada. U poglavlju 4 opisan je eksperiment koji prikazuje razlike u rezultatima segmentacije i trajanju izvođenja između algoritama k-means i fuzzy c-means u primjeni na segmentaciju digitalnih slika.

# 2. GRUPIRANJE PODATAKA I SEGMENTACIJA SLIKE

Grupiranje podataka je postupak kojim se elemente nekoga skupa, opisanih nekim svojstvima, raspoređuje u grupe na način da je sličnost između elemenata unutar iste grupe veća od sličnosti elemenata u različitim grupama. Iako je podatke moguće idealno grupirati postupkom potpune enumeracije, zbog velikog broja načina na koje se podaci mogu rasporediti u grupe, taj postupak nije upotrebljiv za rješavanje problema grupiranja. Iz tog razloga u uporabi su rasprostranjeni algoritmi koji do rješenja dolaze mnogo brže ali ne jamče idealno grupiranje podataka.

Digitalne slike su skupovi podataka koji svakoj točki (engl. *pixel*) pridjeljuju vrijednosti koje opisuju poziciju točke i boju slike u toj točki. Segmentacija slike postupak je koji se provodi nad točkama slike kako bi se slika izmijenila na način koji bolje ističe neka izabrana svojstva slike. Postoje brojne metode segmentacije slike koje daju različite rezultate. Iz tog razloga odabir metode segmentacije slike ovisi o karakteristikama parametara koje se želi istaknuti. Jedan od načina segmentiranja slike je primjena postupaka grupiranja podataka nad točkama slike.

## 2.1. Grupiranje podataka

Grupiranje podataka postupak je koji skup podataka $R$, raspoređuje u $n$ grupa na način da sličnost elemenata, prema nekoj mjeri sličnosti, unutar grupe bude veća nego sličnost elemenata u različitim grupama. Za mjeru sličnosti, prema [1, str. 9], najčešće se koristi neka mjera različitosti, a najčešće korištena mjera različitosti je Euklidska udaljenost. Broj načina na koje se skup elemenata može podijeliti u grupe jednak je Stirlingovom broju druge vrste. Funkcija za izračun Strilingovog broja druge vrste, prema [2, str. 628], prikazana je formulom (2-1).

$$S(k,n) = \frac{1}{n!}\sum_{i=0}^{n}(-1)^{n-i}\binom{n}{i}i^k \tag{2-1}$$

U formuli (2-1) $k$ predstavlja broj elementa za koje se računa Strilingov broj, a $n$ predstavlja broj grupa. Iz tablice 2.1., gdje su prikazane neke odabrane vrijednosti Strillingovog broja druge vrste, može se vidjeti kako broj načina na koje se elementi mogu grupirati u ovisnosti o broju elemenata koje se grupira raste izrazito brzo, te se na temelju toga može zaključiti da izračun mjere sličnosti za svaku kombinaciju elemenata brzo premašuje mogućnosti čak i najjačih računala koja trenutno postoje. Kao rješenje tog problema nastali su učinkoviti

algoritmi za grupiranje podataka koji ne jamče idealno grupiranje, ali u pravilu daju zadovoljavajuće rezultate.

**Tablica 2.1.** *Izračun nekih vrijednosti Stirlingovog broja druge vrste.*

| S(n,m) | m=2 | m=5 | m=10 |
|---|---|---|---|
| n=10 | 511 | 42525 | 1 |
| n=15 | 16383 | $2.1*10^{8}$ | $1.3*10^{7}$ |
| n=25 | $1.7*10^{7}$ | $2.4*10^{15}$ | $1.2*10^{18}$ |
| n=50 | $5.6*10^{14}$ | $7.4*10^{32}$ | $2.6*10^{43}$ |

U postupku grupiranja podataka ključnu ulogu ima funkcija udaljenosti koja određuje koliko su elementi međusobno slični. Stoga je u primjeni algoritama za grupiranje podataka potrebno izabrati funkciju udaljenosti koja dobro opisuje odnose između elemenata grupa željenog rješenja. Uvjeti koje funkcija udaljenosti mora ispunjavati, prema [3, str. 21], su simetrija (engl. *symmetry*), prikazana formulom (2-2), pozitivnost (engl. *positivity*), prikazana formulom (2-3), nejednakost trokuta (engl. *triangle inequality*), prikazana formulom (2-4) i refleksija (engl. *reflexivity*), prikazana formulom (2-5).

$$D(x_i, x_j) = D(x_j, x_i) \tag{2-2}$$

$$D(x_i, x_j) \geq 0, \forall x_i, x_j \tag{2-3}$$

$$D(x_i, x_j) \leq D(x_i, x_k) + D(x_k, x_j), \forall x_i, x_j, x_k \tag{2-4}$$

$$D(x_i, x_j) = 0 \leftrightarrow x_i = x_j \tag{2-5}$$

U formulama (2-2), (2-3), (2-4) i (2-5) oznaka $D$ predstavlja funkciju udaljenosti, a $x_i, x_j$ i $x_k$ predstavljaju elemente za koje se izračunava funkcija udaljenosti.

Ako se naglasak stavi na važnost funkcije udaljenosti onda se problem grupiranja podataka može definirati kao postupak pronalaska grupa za koje funkcija cilja poprima minimalnu vrijednost. Funkcija cilja se najčešće definira kao suma kvadrata udaljenosti elemenata do pripadajućih centroida. Takva definicija čini jasnijom klasifikaciju prema [4, str. 150] koja kaže da traženje optimalne particije spada u NP-teške probleme nekonveksne optimizacije općenito nediferencijabilne funkcije više varijabli, koja najčešće posjeduje značajan broj stacionarnih točaka.

Uz klasično, čvrsto (engl. *hard, crisp*), grupiranje podataka gdje se svaki element pridružuje samo jednoj grupi, postoji i neizrazito (engl. *fuzzy*) grupiranje podataka gdje svaki element u nekoj mjeri pripada svakoj grupi. Takvo, neizrazito, grupiranje podataka pogodnije je u slučajevima kada ne postoji jasna granica između grupa podataka. Zbog različitog shvaćanja pojma skupa uvjeti koje mora zadovoljiti čvrsto grupiranje podataka i uvjeti koje mora

zadovoljiti neizrazito grupiranje podataka se razlikuju. Uvjeti koje, prema [3, str. 5], mora zadovoljiti čvrsto grupiranje podataka su da svaka grupa mora sadržavati barem jedan element, prikazan formulom (2-6), svi elementi moraju biti raspoređeni u grupe, prikazan formulom (2-7) i dvije grupe ne smiju sadržavati niti jedan isti element, prikazan formulom (2-8).

$$X_i \neq \emptyset, i = 1..n \tag{2-6}$$

$$\bigcup_{i=1}^{n} X_i = R \tag{2-7}$$

$$X_i \bigcap X_j = \emptyset, i, j = 1..n, i \neq j \tag{2-8}$$

U formulama (2-6), (2-7) i (2-8) $X_i$ i $X_j$ označavaju grupe elemenata, $R$ označava skup svih elemenata, a $n$ označava broj grupa u koje se elementi raspoređuju. Uvjeti koje, prema [3, str. 5], mora zadovoljiti neizrazito grupiranje podataka su da ukupna pripadnost svakog elementa grupama mora biti jednaka potpunoj pripadnost, prikazan formulom (2-9), i da jedna grupa ne može u potpunosti sadržavati sve elemente, prikazan formulom (2-10).

$$\sum_{j=1}^{n} u_{i.j} = 1, \forall i \tag{2-9}$$

$$\sum_{i=1}^{k} u_{i.j} < k, \forall j \tag{2-10}$$

U formulama (2-9) i (2-10) $u_{i.j}$ predstavlja pripadnost i-tog elementa j-otoj grupi, $n$ označuje broj grupa u koje se elementi raspoređuju, a $k$ označuje ukupan broj elemenata koji se grupiraju.

Postoji mnoštvo algoritama za grupiranje podataka i funkcija udaljenosti koje zadovoljavaju uvjete dane u ovom poglavlju. U daljnjem razmatranju ovaj rad ograničiti će se na algoritme k-means i fuzzy c-means, te Euklidsku udaljenost.

### 2.1.1. Algoritam k-means

Algoritam k-means je iterativan algoritam za čvrsto grupiranje podataka. Zbog jednostavnosti ugradnje smatra se jednim od osnovnih algoritama za grupiranje podataka. Algoritam k-means, prema [2, str. 742], ima vremensku složenost $O(knq)$, gdje je $k$ broj elemenata koji se grupiraju, $n$ broj grupa u koje se elementi raspoređuju i $q$ broj iteracija. Zbog svoje skoro linearne vremenske složenosti algoritam k-means pogodan je za grupiranje velikih skupova podataka.

Rad k-means algoritma zasniva se na centroidima, zamišljenim elementima koji na neki način opisuju skup elemenata, koji predstavljaju grupe u koje se podaci raspoređuju. Centroidi obično poprimaju srednju vrijednost, npr. aritmetičku sredinu, elemenata skupa koji opisuju. Nedostatak centroida je njihova osjetljivost na elemente koji uvelike odskaču od ostatka skupa koji centroid predstavlja.

Parametri algoritma k-means su skup elemenata koji se grupira, broj grupa u koje treba rasporediti elemente te početne vrijednosti centroida. Rad algoritma k-means, prema [1, str. 18], može se na visokoj razini opisati sa četiri koraka, a to su:

1. postavi centroide na početne vrijednosti
2. svaki podatak dodjeli grupi koju predstavlja centroid sa najmanjom udaljenošću od podatka
3. korigiraj centroide grupa prema dodijeljenim podacima
4. ukoliko uvjet prekida nije ispunjen idi na korak 2.

Zbog iterativnog načina rada algoritam k-means u velikom broju slučajeva nalazi lokalni, a ne globalni minimum, funkcije cilja. Funkcija cilja algoritma k-means najčešće se definira kao suma kvadrata udaljenosti svakog elementa do njemu pripadajućeg centorida. Tako definirana funkcija cilja prikazana je formulom (2-11).

$$e^2 = \sum_{j=0}^{n} \sum_{i=0}^{k_j} \left\| x_i^{(j)} - c_j \right\|^2 \tag{2-11}$$

U formuli (2-11) n predstavlja broj grupa u koji se elementi razvrstavaju, $k_j$ predstavlja broj elemenata koji pripadaju j-otoj grupi, $x_i^{(j)}$ predstavlja i-ti element koji pripada j-otoj grupi i $c_j$ predstavlja centroid j-ote grupe.

Minimum koji će biti pronađen ovisi o početnim vrijednostima centroida, stoga je moguće izabrati početne vrijednosti koje će dovesti do globalnog, ili nekog zadovoljavajućeg minimuma. No, prema [3, str. 70], efikasan i općenit način pronalaska takvih početnih vrijednosti centroida ne postoji. Ukoliko se grupiranje provodi nad skupom za koji nisu poznate dobre početne vrijednosti iste se postavljaju na nasumične vrijednosti. Pri tome se vjerojatnost pronalaska zadovoljavajućeg rješenja može povećati višestrukim grupiranjem sa različitim nasumičnim početnim vrijednostima centroida. Pri uporabi algoritma k-means problem može predstavljati i odabir broja grupa u koje se elementi trebaju rasporediti. Kao i za problem odabira početnih uvjeta, prema [3, str. 71], ne postoji efikasan i općenit postupak za odabir broja grupa. Ukoliko se odabir broja grupa ne može provesti u odnosu na skup

elemenata koji se grupira i željeno rješenje onda je pogodnije umjesto algoritma k-means koristiti neki od algoritama koji pri svojem radu, prema nekom kriteriju, sami određuju broj grupa.

### 2.1.2. Algoritam fuzzy c-means

Algoritam fuzzy c-means je iterativan algoritam za neizrazito grupiranje podataka koji se zasniva na algoritmu k-means. Ovaj algoritam ima vremensku složenost $O(kn^2q)$, gdje je $k$ broj elemenata koji se grupiraju, $n$ broj grupa u koje se elementi raspoređuju i $q$ broj iteracija. Pri grupiranju broj elemenata koji se grupiraju je u većini slučajeva puno veći od broja grupa i broja iteracija algoritma, stoga se i za algoritam fuzzy c-means može reći da je gotovo linearan. Zbog gotovo linearne vremenske složenosti algoritam fuzzy c-means pogodan je za grupiranje velikih skupova podataka. Algoritam fuzzy c-means se, kao i algoritam k-means, zasniva na centroidima, te je zbog toga osjetljiv na elemente koji uvelike odskaču od drugih.
Parametri algoritma fuzzy c-means su skup elemenata koji se grupira, broj grupa u koje treba rasporediti elemente, početne vrijednosti centroida i eksponent težine. Rad algoritma fuzzy c-means prikazan u [5, str. 194] može se opisati sa četiri koraka:

1. postavi matricu pripadnosti na početne vrijednosti
2. korigiraj centroide prema pripadnostima elemenata grupama
3. korigiraj matricu pripadnosti prema novim vrijednostima centroida
4. ukoliko uvjet prekida nije ispunjen idi na 2

Zbog iterativnog načina rada algoritam fuzzy c-means pronalazi lokalni minimum, koji je u nekim slučajevima i globalni minimum, funkcije cilja. Funkcija cilja algoritma fuzzy c-means se najčešće definira kao težinska suma kvadrata udaljenosti svakog elementa do centorida svake grupe. Tako definirana funkcija cilja prikazana je formulom (2-12).

$$e^2 = \sum_{j=0}^{n}\sum_{i=0}^{k}(u_{i,j})^m \left\|x_i - c_j\right\|^2 \qquad (2\text{-}12)$$

U formuli (2-12) n predstavlja broj grupa u koji se elementi razvrstavaju, k predstavlja broj elemenata koji se razvrstavaju, $u_{i,j}$ predstavlja pripadnost i-tog elementa j-otoj grupi, m predstavlja eksponent težine, $x_i$ predstavlja i-ti element i $c_j$ predstavlja centroid j-ote grupe.
Pri korištenju algoritma fuzzy c-means pojavljuju se isti problemi sa odabirom početnih vrijednosti centroida i broja grupa kao i pri korištenju algoritma k-means. Eksponent težine je broj koji određuje kojom brzinom pripadnost grupi opada u ovisnosti o udaljenosti elementa od centroida grupe. Prema [6, str. 684], s porastom eksponenta težine raste i pripadnost

udaljenih elemenata skupu, no za male odmake od centroida skupa pripadnost sa povećanjem eksponenta opada.

Usporedi li se rad algoritama k-means i fuzzy c-means može se vidjeti da oba obavljaju isti postupak pri čemu je jedina razlika vrsta skupova koja se koristi. Iz matematike je poznato da se čvrsti skupovi mogu prikazati kao poseban slučaj neizrazitih skupova u kojem elementi ili potpuno pripadaju skupu ili ne pripadaju skupu. Analogno tome može se pokazati da je algoritam k-means poseban slučaj algoritma fuzzy c-means u kojem svaki element u potpunosti pripada samo jednoj grupi.

## 2.2. Segmentacija slike

Segmentacija slike je postupak kojim se točke slike prema nekim njihovim svojstvima, npr. boja, intenzitet ili svjetlina, dijeli u homogene cjeline, a kao cilj ima izmjenu slike na način koji će bolje naglasiti neka odabrana svojstva slike. Zbog široke primjene metoda segmentacije slike i velikog broja algoritama za segmentaciju slika koji daju uvelike različite rezultate nije moguće odrediti mjeru koja bi odredila objektivno najbolji algoritam za segmentaciju slika. Iz tog razloga odabir algoritma za segmentaciju slike i usporedba različitih algoritama za segmentaciju slike se uvijek vrši u ovisnosti o željnom rezultatu segmentacije slike. Postoji nekoliko načina na koje se može ocijeniti koliko dobro je algoritam segmentirao sliku. Jedan od načina je da čovjek ili grupa ljudi pogleda sliku i da svatko procjeni koliko je slika dobro segmentirana. Takav način zahtjeva ljudski rad i zasniva se samo na subjektivnim procjenama ljudi. Drugi način za ocjenu koliko je dobro slika segmentirana je da se odredi odstupanje segmentirane slike od idealno segmentirane slike. Stvaranje takve idealno segmentirane slike se također zasniva na ljudskoj procjeni i zahtjeva određenu količinu ljudskoga rada. No nakon što je stvorena idealna slika postupak usporedbe može se automatizirat, a rezultat se lako može objasniti usporedbom slika. Treći način ocjene segmentirane slike je usporedba odabranih karakteristika segmentirane slike sa karakteristikama željenog rješenja. Pri tome, prema [7, str. 264], postoje četiri standardna kriterija koja se mogu uspoređivati, a to su: „Cjeline trebaju biti jednolike i homogene s obzirom na odabrana svojstva.“, „Susjedne cjeline trebaju se bitno razlikovati s obzirom na svojstva prema kojima su jednolike.“, „Unutrašnjosti cjelina trebaju biti jednostavne i ne sadržavati rupe.“ i „Granice regija trebaju biti jednostavne i prostorno točne.“. Sam izbor kriterija usporedbe i mjere sličnosti usporedbe zasniva se na željenom rezultatu segmentacije slike. Prednost ovakvog ocjenjivanja su objektivnost i mnogo manja potreba za ljudskim radom u odnosu na prve dvije metode.

Algoritmi za segmentaciju slike, prema [8, str. 1], mogu se podijeliti u 7 skupina:

1. Metode temeljene na intenzitetu (engl. *Intensity based methods*)
2. Metode temeljene na diskontinuitetu (engl. *Discontinuity based methods*)
3. Metode temeljene na sličnosti (engl. *Similarity based methods*)
4. Metode temeljene na grupiranju podataka (engl. *Clustering methods*)
5. Metode temeljene na grafovima (engl. *Graph based methods*)
6. Metode temeljene na pixonima (engl. *Pixon based methods*)
7. Hibridne metode (engl. *Hybrid methods*)

Metode temeljene na intenzitetu dijele sliku u dva segmenta prema nekoj graničnoj vrijednosti. Jedan segment sadrži elemente koji promatranu vrijednost imaju veću od granične vrijednosti, a drugi segment one elemente koji promatranu vrijednost imaju manju od granične vrijednosti. Metode temeljene na diskontinuitetu točke slike uspoređuju sa onima oko njih i traže mjesta velike promjene vrijednosti. Takva mjesta proglašavaju se rubovima segmenata, te se prema njima dijele u cjeline. Metode temeljene na sličnosti točke slike uspoređuju sa onima oko njih i ukoliko je sličnost veća od minimalne potrebne sličnosti okolne točke se dodaju u segment, taj se proces nastavlja te se tako cijela slika podjeli u segmente. Metode temeljene na grupiranju podataka pomoću nekog od algoritama za grupiranje podataka grupiraju točke slike, a dobivene grupe su ujedinio i segmenti slike. Metode temeljene na grafovima od točaka slike naprave graf, a zatim prema zadanom kriteriju graf podjele u dijelove čime se i točke slike podjele u segmente. Metode temeljene na pixonima koriste piksone, strukture koje mogu sadržavati više točaka, jednu točku ili neki dio točke slike, kako bi segmentirali sliku. Piksoni poprimaju srednju vrijednost točaka slike koje sadrže. U ovom se postupku prvo sliku podjeli na piksone, a zatim se nekom drugom metodom segmentacije iz piksona dobivaju segmenti slike. Hibridne metode kombiniraju dvije ili više metoda segmentacije slika kako bi se dobili bolji rezultati ili bolje vrijeme izvođenja nego korištenjem samo jedne metode.

### 2.2.1. Primjena segmentacije slike

Segmentacija slike najčešće se ne primjenjuje samostalno već kao jedan od koraka kojima računalni program dolazi do rješenja. Zbog svoje neovisnosti o primjeni metode segmentacije slike uspješno su primijenjene pri rješavanju mnogih problema. Jedna od primjena segmentacije slike u računarstvu, prikazana u [9], je sažimanje slike. Pri tom postupku slika se segmentira prema boji u velik broj grupa. Nakon segmentacije svakoj grupi se pridijeli boja koja dobro predstavlja točke te grupe. Ukoliko je razlika između boje točaka i boje

njihovih pripadajućih grupa dovoljno mala ona će za ljudsko oko biti gotovo neprimjetna. Pohranjivanjem segmenata i pripadnosti točaka pojedinim segmentima sliku je moguće pohraniti korištenjem manjeg broja bitova no što bi bilo potrebno za pohranu boje svake točke slike.

Segmentacija slike primjenu je pronašla i u medicini gdje se, kao što je prikazano u [10], može koristiti pri raspoznavanju tumora od zdravog tkiva na endoskopskim snimkama. Metoda raspoznavanja zasniva se na različitom reflektiranju svjetlosti tkiva tumora i zdravoga tkiva. Kada se tkivo osvijetli plavim laserom ono zdravo reflektira zelenkastu boju, a tkivo tumora crvenkastu boju. Segmentacijom tako nastale slike prema boji računalo može razlikovati tkivo tumora od zdravog tkiva. S obzirom da endoskopske snimke sadrže značajnu količinu šuma postupak segmentacije slike može dati prevelik broj grupa, stoga se nakon segmentacije grupe koje su manje od neke granične vrijednosti spajaju sa najvećim susjednim grupama.

Drugi primjer segmentacije slike koji također dolazi iz medicine, prikazan u [11], je izdvajanje krvnih žila mrežnice iz slike oka. Slike oka sadrže značajnu količinu šuma i neujednačenu boju pozadine. Iz tog razloga je za postizanje zadovoljavajućih rezultata prije segmentacije sliku potrebno dodatno obraditi kako bi se što je više moguće ujednačila boja pozadine i maknuo šum. Zatim se takva, obrađena, slika segmentira prema boji kako bi se sa slike izdvojile krvne žile, te se kao rezultat ovoga postupka dobiva slika koja prikazuje samo krvne žile oka.

### 2.2.2. Grupiranje podataka za segmentaciju slike

Digitalna slika je skup podataka koji svakoj točki slike na neki način pridjeljuje boju. Na segmentaciju slike može se gledati kao na raspoređivanje točaka slike u grupe prema nekom njihovom svojstvu. Jedan od mnoštva načina za segmentaciju je primjena algoritama za grupiranje podataka na točke slike. No prije no što se točke mogu grupirati algoritmom za grupiranje podataka potrebno je definirati funkciju sličnosti. Najjednostavniji način za definiciju funkcije sličnosti je primjena euklidske udaljenosti na parametre točaka koji govore o boji ili intenzitetu točke. Ovisno o algoritmu koji se koristi uz skup točaka slike i funkciju udaljenosti algoritmu za grupiranje podataka može biti potrebno predati još neke parametre, tako primjerice algoritam k-means zahtjeva da mu se preda i broj grupa u koje treba rasporediti rješenja, a algoritam fuzzy c-means zahtjeva da mu se preda broj grupa u koje treba rasporediti rješenja i eksponent težine (engl. *fuzzifier*). Kao rezultat izvođenja algoritma za grupiranje podataka dobivaju se točke raspodijeljene u grupe na način da je udaljenost,

prema definiranoj funkciji udaljenosti, od svake točke grupe do srednje vrijednosti grupe minimalna. Nakon grupiranja točaka svakoj se grupi na neki način pridijeli boja. Jedan od načina je pridjeljivanje prije određenih boja grupama. Kao primjer na taj način određenih boja može se navesti pridjeljivanje bijele boje za grupu koja predstavlja pozadinu i crne za grupu koja predstavlja objekt koji se želi istaknuti. Drugi način je da se grupama pridijele na neki način izračunate boje, primjerice aritmetička sredina parametara boje točaka unutar svake grupe. Nakon toga se stvara nova slika koja ima iste dimenzije kao i izvorna slika, ali je obojena na način da se svakoj točki pridijeli boja grupe kojoj pripada točka na istom mjestu na izvornoj slici. Na taj način obojena slika je rezultat segmentacije slike.

# 3. OSTVARENO PROGRAMSKO RJEŠENJE

Ostvareno programsko rješenje izrađeno je u programskom jeziku C# uz korištenje Microsoft .NET radnog okvira i radnog okvira Windows forme za izradu grafičkog sučelja. U ostvarenom programskom rješenju, pomoću grafičkog sučelja, korisnik može odabrati sliku koju želi segmentirati te nakon segmentacije spremiti segmentiranu sliku. Korisnik putem grafičkog sučelja može odabrati jedan od dva ugrađena algoritma za grupiranje podataka, k-means i fuzzy c-means, pomoću kojih se slika segmentira te postaviti parametre potrebne za korištenje odabranog algoritma.

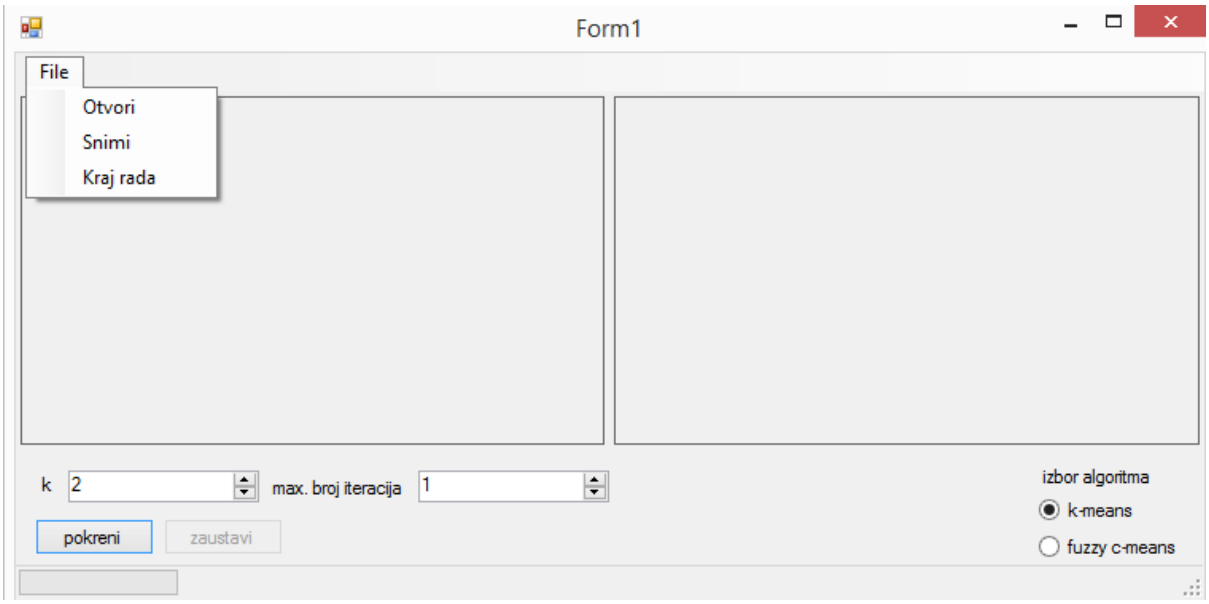
## 3.1. Način rada programskog rješenja

Programsko rješenje može se podijelit na dva dijela grafičko korisničko sučelje i ugradnju algoritama za segmentaciju slike pomoću algoritmima za grupiranje podataka. Grafičko sučelje izrađeno je u radnom okviru Windows forme, a pri izradi su korišteni samo standardni elementi koji dolaze uključeni u radni okvir. Putem grafičkog sučelja korisnik može odabrati sliku koju želi segmentirati. Podržani formati slike su BMP, GIF, EXIF, JPG, PNG i TIFF. Korisnik, putem grafičkog sučelja, može postaviti željeni broj grupa rješenja i maksimalan broj iteracija algoritma za grupiranje podataka, oba parametra su ograničena na raspon od 1 do 100, te može odabrati jedan od dva ugrađena algoritma za grupiranje, k-means i fuzzy c-means, pomoću kojih se vrši segmentacija slike. Na zahtjev korisnika započinje se postupak segmentacije slike, a tijekom segmentacije korisnik može zatražiti prijevremeni prekid izvođenja. Sam postupak segmentacije slike izvršava se u radnoj niti kako bi se korisničko sučelje, koje se izvodi u glavnoj niti programa, moglo koristiti i tijekom postupka segmentacije. Tijekom postupka segmentacije slike korisniku se nakon svake iteracije algoritma za grupiranje podataka prikazuje trenutna segmentacija slike. Algoritmi za grupiranje podataka i segmentacija slike u ovom programskom rješenju ugrađeni su kao jedna cjelina, tj. kao ulaz u algoritam predaje se slika, zatim se nad točkama slike provodi proces grupiranja, te algoritam kao rezultat vrati sliku obojenu u ovisnosti o pripadnosti točaka grupama. Početne vrijednosti centroida u oba ugrađena algoritma postavljaju se na vrijednosti parametara boje nasumično odabrane točke početne slike. Boje prema kojima se boji segmentirana slika dobivaju se izračunom aritmetičke sredine crvene, plave i zelene komponente boje točaka svake grupe. Pri grupiranju kao funkcija udaljenosti koristi se euklidska udaljenost primijenjena na crvenu, plavu i zelenu komponentu boje točke. Uvjeti prekida izvođenja algoritma grupiranja su dostizanje maksimalnog broja iteracija i dostizanje

stanja u kojem nema promjene u dva uzastopna koraka. Tijekom segmentacije programsko rješenje prati vrijeme izvođenja i izvedeni broj iteracija, te nakon segmentacije ispisuje te podatke u statusnu traku. Nakon segmentacije slike korisnik pomoću grafičkog sučelja može segmentiranu sliku spremiti u BMP ili JPEG formatu.

## 3.2. Prikaz i način uporabe programskog rješenja

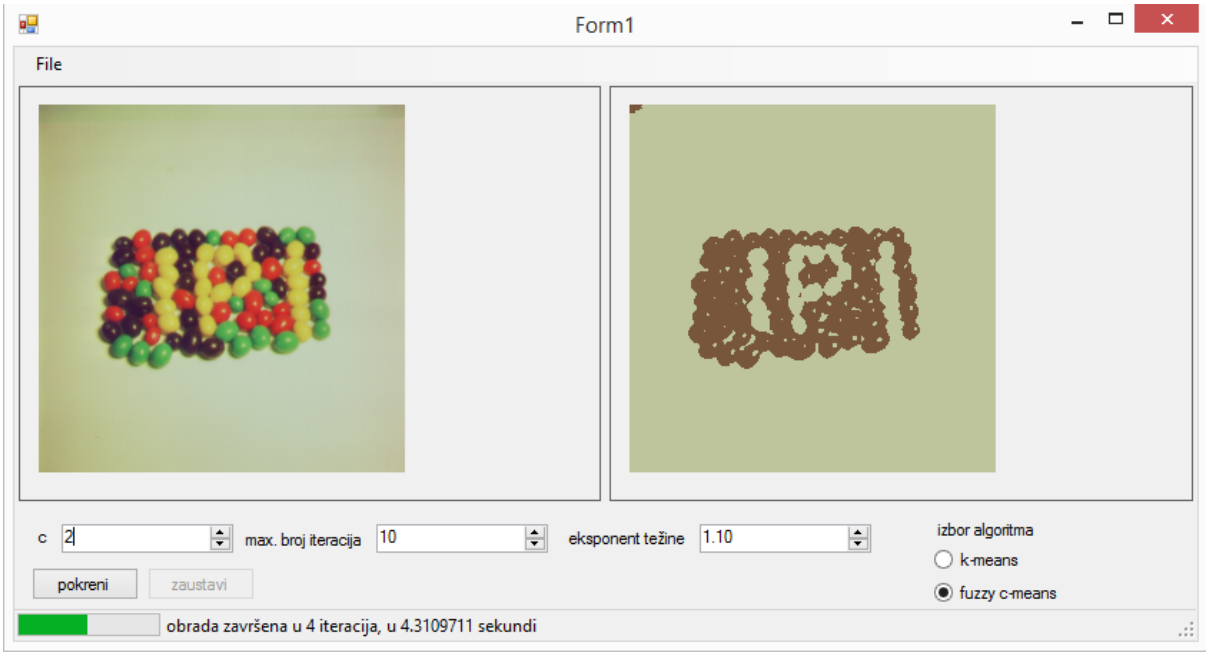
Kako bi se korisnik lakše mogao snaći u programu u kojem prije nije radio treba mu dati upute za korištenje programa. Na gornjem lijevom kraju slike 3.1. može se vidjeti padajući izbornik sa opcijama Otvori, Snimi i Kraj rada. Ukoliko se odabere opcija otvori, pojavljuje se prozor za otvaranje dokumenta, pomoću kojeg se može odabrati sliku za segmentiranje u BMP, GIF, EXIF, JPG, PNG ili TIFF formatu. Ukoliko se odabere opcija snimi pojavljuje se prozor za snimanje dokumenta koji snima segmentiranu sliku u BMP ili JPEG formatu. Izborom opcije Kraj rada prekida se rad programa. Ispod padajućeg izbornika vide se dva uokvirena kvadrata. Unutar njih prikazuju se slike, na lijevoj strani izvorna slika, a na desnoj strani segmentirana slika. Ispod mjesta za prikaz slika vide se polja za unos parametara.




**Slika 3.1.** *Aplikacija prije obrade slike.*

Na slici 3.1. može se vidjeti kako izgledaju polja za unos parametara ukoliko je odabran algoritam k-means, a na slici 3.2. kako ista izgledaju ukoliko je odabran algoritam fuzzy c-means. Ispod polja za unos nalaze se dva gumba, jedan za pokretanje segmentacije slike, a drugi za prijevremeno zaustavljanje segmentacije slike. Desno od polja sa parametrima i gumba koji su upravo opisani nalazi se izbor algoritma koji dopušta izbor jedne od dvije

opcije za odabir algoritma za grupiranje k-means i fuzzy c-means. Na dnu prozora može se vidjeti statusna traka, u njoj se nalaze dva elementa. S lijeve strane nalazi se grafički indikator koji pokazuje koliko se iteracija od maksimalnog broja iteracija izvršilo. Desno od njega nalazi se tekstualni izlaz iz programa pomoću kojeg program, u tekstualnom obliku, daje informacije o statusu svoga izvođenja. Slika 3.1. prikazuje program prije učitavanja originalne slike i segmentacije. Slika 3.2. prikazuje program nakon segmentacije algoritmom fuzzy c-means.




**Slika 3.2** *Aplikacija nakon obrade slike.*

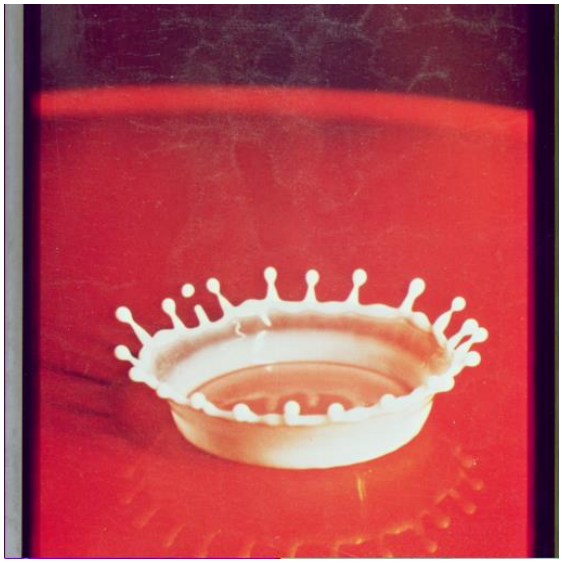
# 4. EKSPERIMENTALNA ANALIZA

Kako bi se vidjele razlike između segmentacija koje daju algoritmi k-means i fuzzy c-means potrebno je napraviti eksperimentalnu usporedbu njihovih rezultata. Za usporedbu su bile korištene tri standardne slike, preuzete sa [12], segmentirana sa svakim algoritmom (osnovne informacije o korištenim slikama dane su u Tablici 4.1). Eksponent težine ima utjecaj na rezultat segmentacije algoritma fuzzy c-means, stoga se eksperiment izvodi sa više različitih postavki tog parametra. Tri standardne slike nad kojima se vršila usporedba su „*jelly beans*“ (Slika 4.1.), „*splash*“ (Slika 4.2.) i „*tree*“ (Slika 4.3.).



**Slika 4.1.** *jelly beans*

Slika 4.1., „*jelly beans*“, dolazi u TIFF formatu i veličine je 256x256 točaka opisanih sa 24 bita po točki. Ova slika je odabrana za usporedbu zato što sadrži objekte u nekoliko različitih boja i podlogu koja nije jednobojna.



**Slika 4.2.** *splash*

Slika 4.2., „*splash*“, dolazi u TIFF formatu i veličine je 512x512 točaka opisanih sa 24 bita po točki. Ova slika izabrana je zato što se boja pozadine i boja objekta uvelike razlikuju, a slika sadrži značajnu količinu šuma gornjem dijelu slike te sadrži linije koje mogu ometati rad algoritama sa lijeve i desne strane slike.



**Slika 4.3.** *tree*

Slika 4.3., „*tree*“, dolazi u TIFF formatu i veličine je 256x256 točaka opisanih sa 24 bita po točki. Ova slika sadrži mnoštvo različitih boja, te zato dobro predstavlja slike kakve se susreću u svakodnevnom životu. Ova slika sadrži i mnoštvo detalja na kojima se može primijetiti gubitak kvalitete slike nakon segmentacije.

**Tablica 4.1.** *Osnovne informacije o slikama.*

| naziv slike | poveznica | veličina |
|---|---|---|
| *jelly beans* | http://sipi.usc.edu/database/download.php?vol=misc&img=4.1.07 | 256x256 |
| *splash* | http://sipi.usc.edu/database/download.php?vol=misc&img=4.2.01 | 512x512 |
| *tree* | http://sipi.usc.edu/database/download.php?vol=misc&img=4.1.06 | 256x256 |

## 4.1. Postavke eksperimenta

Provedeni eksperiment se sastoji od tri nezavisna djela. Svaki dio prati segmentaciju slike algoritama k-means i fuzzy c-means na jednoj od tri standardne slike. Eksponent težine može uvelike utjecati na rezultat algoritma fuzzy c-means stoga se isti u svakom djelu izvodi sa vrijednostima eksponenta težine 1.1, 2 i 5. Način vrednovanja rezultata sastoji se od vizualne inspekcije rezultata segmentacije različitim algoritmima i usporedbe vremena potrebnog za izvođenje svakog od algoritama. Jedan od faktora koji nije bio kontroliran u ovom eksperimentu su početne vrijednosti centroida, koje su izabrane nasumično, a koje utječu na

potreban broj iteracija za izvršenje algoritma i na konačan rezultat segmentacije. U svakom djelu eksperimenta maksimalan broj iteracija ograničen je na 64 kako bi algoritmi za grupiranje podataka mogli izvršiti dovoljno iteracija za pronalazak zadovoljavajućeg rješenja i u slučajevima kada nisu izabrane dobre vrijednosti početnih centroida. Broj grupa za svaku sliku određen je u ovisnosti o svojstvima slike. Slika „*jelly beans*“ segmentira se u šest grupa, po jedna grupa za svaku boju elementa na slici i dvije grupe za pozadinu. Slika „*splash*“ segmentira se u tri grupe, jedna grupa za crnu pozadinu, jedna grupa za crvenu pozadinu i jedna grupa za bijelu tekućinu prikazanu na slici. Slika „*tree*“ segmentira se u 16 dijelova kako bi slika zadržala izgled sličan izvornoj slici, tj. kako bi se mogao uspoređivati gubitak detalja uzrokovan različitim metodama segmentacije.

## 4.2. Rezultati

Usporedbom slika prikazanih u tablici 4.2. može se vidjeti da je slika „*jelly beans*“ bolje segmentirana pomoću algoritma k-means i algoritma fuzzy c-means pri eksponentu težine 2. Segmentacije slike pomoću algoritma fuzzy c-means pri eksponentima težine 1.1 i 5 su pozadinu razdvojile u više segmenata,a neki objekti različitih boja stavljeni su u isti segment.

**Tablica 4.2.** *Segmentacija slike „jelly beans“.*

| | |
|---|---|
|  |  |
| orginalna slika | k-means |

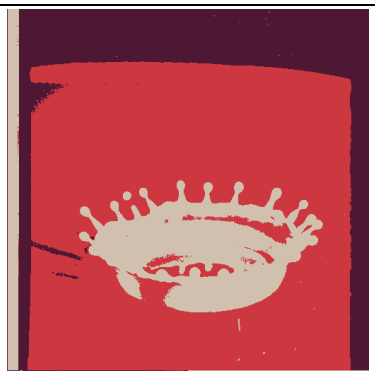
| | | |
|---|---|---|
|  |  |  |
| Fuzzy c-means (c = 1.1) | Fuzzy c-means (c = 2) | Fuzzy c-means (c = 5) |

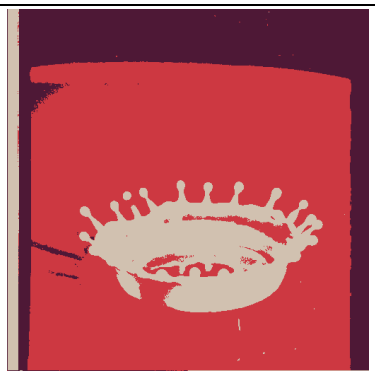
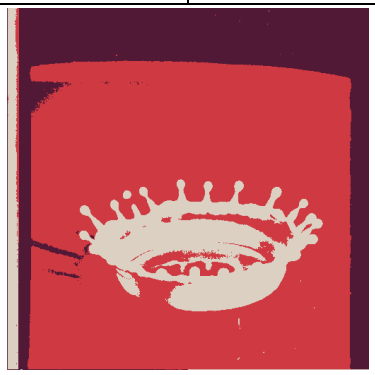
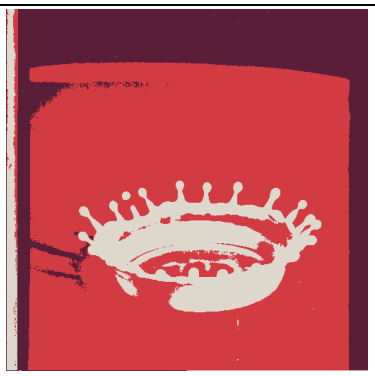
**Tablica 4.3.** *Trajanje segmentacije slike „jelly beans“.*

| algoritam | ostvaren broj iteracija | trajanje [s] |
|---|---|---|
| k-means | 32 | 69.1 |
| fuzzy c-means, (c = 1.1) | 17 | 59.21 |
| fuzzy c-means, (c = 2) | 51 | 173.79 |
| fuzzy c-means, (c = 5) | 57 | 190 |

U skupu slika, prikazanom u tablici 4.4., može se vidjeti kako su svi algoritmi segmentirali sliku na sličan način. Razlog tome je velika razlika u boji objekta i podloge, što je pogodno za korištenje metode grupiranja podataka za segmentaciju slike. Također može se vidjeti da su bijele točke u gornjem dijelu slike u svim slučajevima nakon segmentacije nestale. No uz lijevi rub može se vidjeti linija, koja ne pripada objektu, ali je smještena u istu grupu kao objekt zbog slične boje na originalnoj slici.

**Tablica 4.4.** *Segmentacija slike „splash“.*

| | |
|---|---|
|  |  |
| Orginalna slika | k-means |

| | | |
|---|---|---|
|  |  |  |
| Fuzzy c-means (c=1.1) | Fuzzy c-means (c=2) | Fuzzy c-means (c=5) |

**Tablica 4.5.** *Trajanje segmentacije slike „splash“.*

| algoritam | ostvaren broj iteracija | trajanje [s] |
|---|---|---|
| k-means | 6 | 36.7 |
| fuzzy c-means, (c = 1.1) | 6 | 23.61 |
| fuzzy c-means, (c = 2) | 13 | 65.63 |
| fuzzy c-means, (c = 5) | 24 | 117.91 |

Usporedbom slika prikazanih u tablici 4.6. može se vidjeti da nema značajnije razlike u načinu na koji su slike segmentirane. U svim su slučajevima izgubljeni su detalji vode i kopna u pozadini, dok su detalji drveta i trave ostali dobro očuvani.

**Tablica 4.6.** *Segmentacija slike „tree“.*

| | |
|---|---|
|  |  |
| Orginalna slika | k-means |

| | | |
|---|---|---|
|  |  |  |
| Fuzzy c-means (c=1.1) | Fuzzy c-means (c=2) | Fuzzy c-means (c=5) |

**Tablica 4.7.** *Trajanje segmentacije slike „tree“.*

| algoritam | ostvaren broj iteracija | trajanje [s] |
|---|---|---|
| k-means | 45 | 215.771 |
| fuzzy c-means, (c = 1.1) | 37 | 738.75 |
| fuzzy c-means, (c = 2) | 28 | 561.33 |
| fuzzy c-means, (c = 5) | 32 | 628.8 |

# 5. ZAKLJUČAK

Cilj ovoga rada bio je dati uvod u grupiranje podataka i segmentaciju slike, te povezati ta dva područja. Također, bio je potrebno izraditi računalni program koji vrši segmentaciju slike pomoću algoritama za grupiranje podataka. Uz pomoć programa bilo je potrebno napraviti eksperimentalnu analizu kojom se uspoređuje segmentacija slike algoritmima za grupiranje podataka k-means i fuzzy c-means. Jedan težak dio posla pri segmentiranju slike pomoću algoritama za grupiranje podataka je izbor prikladnog broja grupa, što direktno utječe na brzinu i kvalitetu segmentacije slike. Eksperimentalna analiza pokazala je kako oba algoritma mogu dati slične rezultate, te kako različite vrijednosti eksponenta težine fuzzy c-means algoritma mogu dati različite rezultate. Također eksperiment je pokazao kako algoritam k-means u velikom broju slučajeva ima kraće vrijeme izvođenja od algoritma fuzzy c-means. Ovaj rad može se proširiti na nekoliko načina. Jedan od načina za takvo proširenje je uporaba objektivnijeg kriterija za usporedbu rezultata segmentacije slike različitim metodama. Kao što je navedeno u drugom poglavlju rada, objektivniji kriterij usporedbe može biti odstupanje segmentirane slike od idealne segmentacije slike ili usporedba karakteristika dobivenih segmenata. Programsko rješenje napravljeno za potrebe ovoga rada koristi jednu nit izvođenja za izračune, no izračuni udaljenosti točaka slike do centroida unutar iste iteracije mogu se vršiti istovremeno. Stoga, drugi način na koji se ovaj rad može proširiti je ugradnjom algoritama za grupiranje podataka koja omogućuje paralelno izvođenje izračuna udaljenosti.

## LITERATURA

[1] A. K. Jain, M. N. Murty, and P. J. Flynn, Data clustering: a review, ACM Computing Surveys, Vol. 31, pp. 264–323, 1999.

[2] S. Theodoridis and K. Koutroumbas, Pattern Recognition 4th Edition, Academic Press, 2008.

[3] R. Xu, D. C. Wunsch, Clustering, Hoboken, New Jersey, John Wiley & Sons Inc., 2007.

[4] K. Sabo, R. Scitovski, I. Vazler, Grupiranje podataka: klasteri, Osječki Matematički List, Vol. 10, pp. 149–178, 2010.

[5] J. C. Bezdek, R. Ehrlich, W. Full, FCM: The fuzzy c-means clustering algorithm, Computers & Geosciences, Vol. 10, no. 2–3, pp. 191–203, 1984.

[6] F. Hoppner, F. Klawonn, A contribution to convergence theory of fuzzy c-means and derivatives, IEEE Transactions on Fuzzy Systems, Vol. 11, pp. 682–694, 2003.

[7] H. Zhang, J. E. Fritts, S. A. Goldman, Image segmentation evaluation: A survey of unsupervised methods, Computer Vision and Image Understanding, Vol. 110, pp. 260–280, 2008.

[8] A. M. Khan, S. Ravi, Image segmentation methods: A comparative study, International Journal of Soft Computing and Engineering, Vol. 3, no. 4, pp. 84–92, 2013.

[9] W. Kwedlo, A clustering method combining differential evolution with the k-means algorithm, Pattern Recognition Letters, Vol. 32, pp. 1613–1621, 2011.

[10] M. Frackiewicz, H. Palus, KHM clustering technique as a segmentation method for endoscopic colour images, International Journal of Applied Mathematics and Computer Science, Vol. 21, pp. 203–209, 2011.

[11] Y. Yang, S. Huang, N. Rao, An automatic hybrid method for retinal blood vessel extraction, International Journal of Applied Mathematics and Computer Science, Vol. 18, pp. 399–407, 2008.

[12] SIPI Image Database, University of Southern California, dostupno na: sipi.usc.edu/database/ [Lipanj 2018]

## SAŽETAK

U ovom radu napravljena je usporedba algoritama za grupiranje podataka primijenjenih na segmentaciju slike. Rad ukratko opisuje probleme grupiranja podataka i segmentacije slike. Posebna pažnja posvećena je algoritmima za grupiranje podataka k-means i fuzzy c-means i njihovoj primjeni za segmentaciju slike. Za potrebe rada napravljeno je programsko rješenje pomoću kojega se slike mogu segmentirati korištenjem algoritma k-means ili fuzzy c-means. Programsko rješenje izrađeno je u programskom jeziku C# uz korištenje radnih okvira Microsoft .NET i Windows forme. Usporedba algoritama provedena je na tri standardne slike. Svaka slika segmentirana je algoritmima k-means i fuzzy c-means sa eksponentima težine 1.1, 2 i 5. Dobiveni rezultati vrednovani su vizualnom inspekcijom slika i usporedbom vremena izvođenja algoritama.



Ključne riječi: grupiranje podataka, segmentacija slike, k-means, fuzzy c-means, programski jezik C#



## ABSTRACT

**A comparison of crisp and fuzzy data clustering algorithms for image segmentation**

This paper provides comparison of clustering based image segmentation methods. Paper gives short introduction to image segmentation and clustering. Greater attention was given to k-means and fuzzy c-means clustering algorithms and their application in image segmentation. Software for image segmentation by using k-means or fuzzy c-means algorithm was implemented as part of writing this paper. Software was implemented in programming language C# with Microsoft .NET and Windows forms frameworks. Three standard images were used for comparison of image segmentation algorithms. Each image was segmented with k-means and fuzzy c-means with fuzzifier value of 1.1, 2 and 5. Results of segmentations were evaluated by visual inspection and comparison of execution times.



Key words: clustering, image segmentation, k-means, fuzzy c-means, C# programming language

# ŽIVOTOPIS

Luka Loina rođen je 8. Lipnja 1993 u Osijeku. Djetinjstvo provodi u Donjem Miholjcu gdje godine 2000. počinje pohađati Osnovnu Školu August Harambašić. Osnovnu školu završava godine 2008., a zatim iste godine upisuje opću gimnaziju u Srednjoj Školi Donji Miholjac. Srednjoškolsko obrazovanje završava u godini 2012., a nakon položene državne mature upisuje preddiplomski studij računarstva na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija u Osijeku.