

SEGMENTACIJA CT SLIKE POMOĆU SAMO-ORGANIZIRAJUĆIH NEURONSKIH MREŽA

Marko Martinović, Antun Stoić i Darko Kiš

Prethodno priopćenje

U radu se prikazuje postupak segmentacije i označavanja CT (Computed Tomography) slika, koristeći samo-organizirajuće neuronske mreže. U postupku segmentacije koriste se obilježja (features) koja su dodijeljena svakom pikselu na slici. Obilježja, koja se u radu koriste, potječe iz skalirane porodice diferencijsko-geometrijsko nepromjenjivih obilježja, i čine ulaz u neuronsku mrežu. Neuronska mreža, nakon učenja, vrši klasifikaciju piksela u jednu od regija.

Ključne riječi : CT slika, neuronske mreže, obilježja, segmentacija

Segmentation of the CT image using self-organizing neural networks

Preliminary notes

A presentation of the segmentation and extraction process of CT (Computed Tomography) images, using self-organizing neural networks has been given. The image features have been used during segmentation process and adopted for each pixel on image. The origin of the features, used in this paper, are the scaled differential-geometrical features which are the entering data for neural network. Neural network, after training, dissipates the pixels into one of the image regions.

Key words: CT image, features, neural networks, segmentation

1

Uvod

Introduction

Vizualno spoznavanje objekata i njihovih promjena koristeći dvodimenzionske prikaze postaje sve važnijim elementom razvoja. Postupak digitalne obrade slike koristi se za prepoznavanje objekata u različitim područjima, a najčešće u tehnički, kontroli kvalitete, telekomunikacijama i medicini. Obrada slike provodi se slijedno, faza po faza ili se može provoditi uz povrat na neku od ranije provedenih faza. Postupak obrade s povratom je novijeg datuma, a primijenjen je u robotici za određivanje kutova u slikama procesa zavarivanja u brodogradnjici [1].

Za automatsku segmentaciju složenih medicinskih slika postoji veliki broj metoda. Kvaliteta pojedine metode ovisi o algoritmima za obradu slika tj. tehnički preuzimanja podataka iz slike. Za obradu slike, autori u radu [2] koriste MatLab Image Toolkit, a za programiranje C++ programske jezik. Tehnike preuzimanja podataka su obično vezane za ekspertne sustave i logiku i mogu se podijeliti u dva osnovna tipa: regionalno-bazirana segmentacija i rubno-bazirana segmentacija. Regionalno-bazirana tehnika realizira se pomoću homogenosti piksela, tj. obilježja koje govori o homogenosti njegove okoline. Uz tu tehniku obično se koristi ekspertni sustav, pa se samo-organizirano grupiranje regija provodi zaključivanjem pomoću neizrazite logike.

Rubno-bazirana segmentacija oslanja se na konture slike [3], koje koristi za optimiranje granica između regija i širenje kontura na susjedne regije.

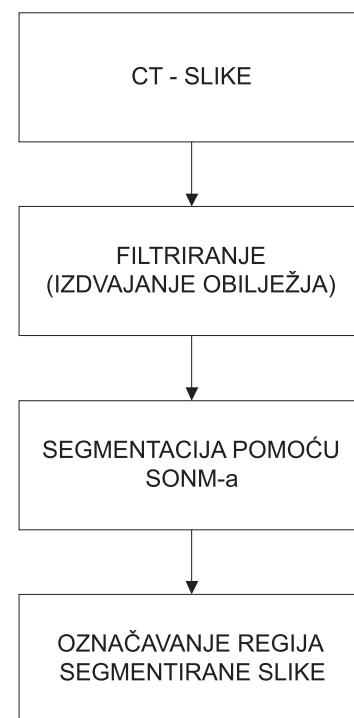
Pristup koji se u radu koristi baziran je na samo-organizirajućim neuronskim mrežama (SONM), koje segmentiraju sliku na principu klasifikacije piksela u jednu od regija. Broj regija je parametar koji se zadaje pri pozivu funkcije, a broj obilježja kombinira se ovisno o potrebi.

2

Metoda segmentacije

Segmentation method

Na slici 1, prikazana je metoda segmentacije. U prvoj fazi rada algoritma, prikupljaju se podaci. Nakon toga se iz podataka izdvajaju obilježja koja kasnije služe kao ulaz u neuronsku mrežu. Nakon što je segmentacija završila, slijedi označavanje regija i iscrtavanje rezultata.



Slika 1 Dijagram toka postupka segmentacije CT slike
Figure 1 Flow chart of the segmentation process of the CT image

2.1

Izdvajanje obilježja Features extraction

Obilježja koja se koriste u radu mogu se svrstati u tri grupe:

1. Podatkovno-neovisna obilježja. To su obilježja koja ne ovise o slici nego o nekim drugim parametrima. U konkretnom slučaju to je geometrija, točnije koordinate unutar okvira slike.
2. Direktno pikselno-ovisna obilježja. U ovom radu, to je vrijednost piksela (grayscale).
3. Nisko propusni filtri, koji računaju srednju vrijednost piksela u njegovoj okolini i od filtara, prema [4].

Programski zapis funkcije koja izdvaja obilježja ima sljedeći oblik:

```
(1) %funkcija ekstrahira pojedine osobine iz matrice, (slike)
(2) function F = ExtractFeatures(A)
(3) F = zeros(9, size(A, 1)*size(A, 2));
```

```
(4) pom1 = niskopropusnifilter1 (A, 50, 1);
(5) pom2 = niskopropusnifilter1 (A, 50, 2);
(6) pom3 = niskopropusnifilter1 (A, 50, 5);
```

```
(7) pom4 = niskopropusnifilter2 (A, 50, 1);
(8) pom5 = niskopropusnifilter2 (A, 50, 2);
(9) pom6 = niskopropusnifilter2 (A, 50, 3);
```

```
(10) for i=1:size(A, 1)
(11)   for j=1:size(A, 2)
(12)     F( 1, (i-1)*size(A, 1) + j ) = i;
(13)     F( 2, (i-1)*size(A, 1) + j ) = j;
(14)     F( 3, (i-1)*size(A, 1) + j ) = GrayScale(A, i, j);

(15)    F( 4, (i-1)*size(A, 1) + j ) = pom1(i, j);
(16)    F( 5, (i-1)*size(A, 1) + j ) = pom2(i, j);
(17)    F( 6, (i-1)*size(A, 1) + j ) = pom3(i, j);

(18)    F( 7, (i-1)*size(A, 1) + j ) = pom4(i, j);
(19)    F( 8, (i-1)*size(A, 1) + j ) = pom5(i, j);
(20)    F( 9, (i-1)*size(A, 1) + j ) = pom6(i, j);

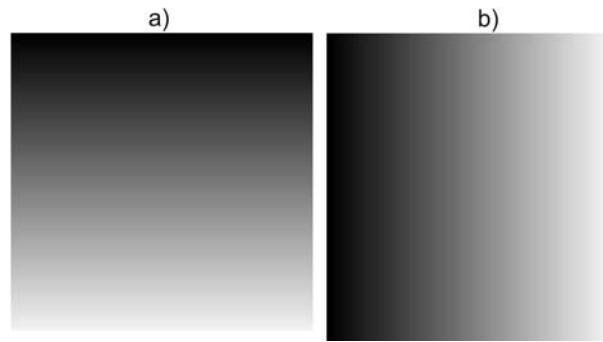
(21) end
```

Funkcija "ExtractFeatures", kao parametar uzima sliku. U (3) su definirane dimenzije polja obilježja, a samim time i njihova broja. Od (10)-(21) vrši se punjenje polja obilježjima.

2.1.1

Podatkovno-neovisna obilježja Data nondependent features

Podatkovno-neovisna obilježja na slikama 2a i 2b su absolutne koordinate ($x-y$) piksela, gledajući od gornjeg lijevog kuta. Svojstvo s istim obilježjem označeno je s istom nijansom (s istim grayscale-om). Slika 2a prikazuje y koordinatu kao obilježje, dok slika 2b x koordinatu. Ova obilježja su kako je i ranije navedeno neovisna o samom ulaznom podatku, tj. CT slici.



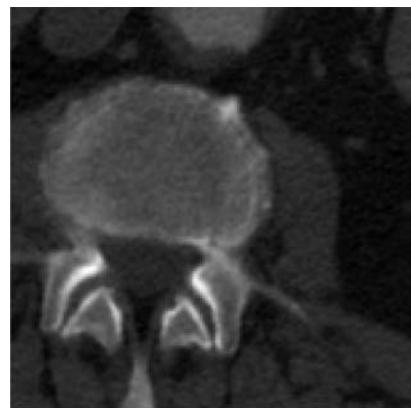
Slika 2 Podatkovno-neovisna obilježja: a) y koordinata ; b) x koordinata
Figure 2 Data nondependent features: a) y coordinate; b) x coordinate

2.1.2

Direktno pikselno-ovisna obilježja Direct pixel-dependant features

Iz ulazne CT slike, prikazane slikom 3, pikselno-ovisna obilježja preuzimaju se matricom A koja ima funkciju:

```
function Gray = GrayScale(A, i, j)
Gray = A(i,j);
```



Slika 3 Ulazna CT slika
Figure 3 Input CT image

2.1.3

Nisko-propusni filteri

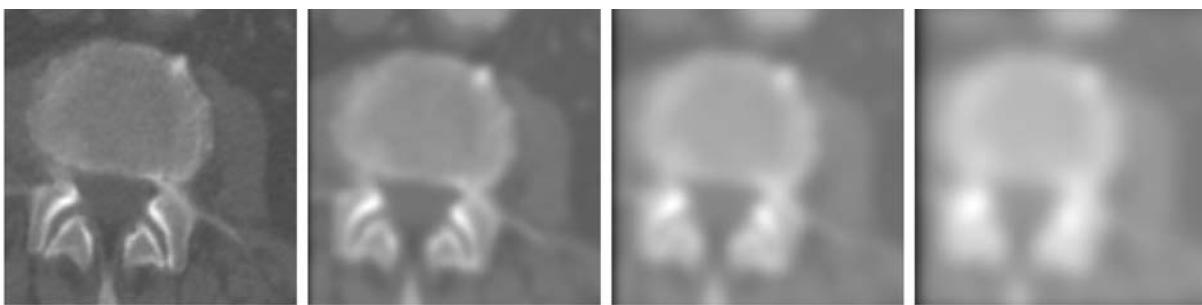
Low pass filter

- a) Određivanje srednje vrijednosti piksela u njegovoj okolini realiziranog pomoću nisko-propusnog filtera

Naredbe u funkciji "ExtractFeatures" označene sa (4)-(6) i (15)-(17) definiraju ovu akciju. Prvo se provodi izračunavanje obilježja, a nakon toga obilježja se spremaju u polje obilježja. Dimenzija obilježja uz konstantan ulazni parametar jednaka su kao i dimenzija slike. Stoga se zbroj obilježja uz određeni parametar može slikovito prikazati. Kod izračunavanja obilježja poziva se funkcija "NiskoPropusniFilter1". Ta funkcija je ustvari definirana kao konvolucija Gaussove funkcije s dvije varijable i same slike.

Gaussova funkcija s dvije varijable glasi:

$$G(x, y) = \frac{1}{\sigma^2 \cdot 2 \cdot \pi} \cdot e^{-\frac{(x^2 + y^2)}{2\sigma^2}} \quad (1)$$



*Slika 4 Izdvajanje obilježja slike pomoći niskopropusnog filtra
Figure 4 The image feature extraction using low pass filter*

Gausova funkcija opisana je pomoću ugrađene "MatLab" funkcije. Izlaz ove funkcije je kvadratna matrica, dimenzija jednakih ulaznom parametru "dim". Matrica je realizirana na način da indeksi matrice predstavljaju koordinate, a elementi matrice vrijednosti Gaussove funkcije na dotočnim koordinatama. Središnji element se uzima kao ishodište koordinatnog sustava. Dakle, ovdje se radi o relativno gruboj diskretnoj aproksimaciji Gaussove funkcije.

Dobivanje nisko-propusno filtrirane slike, tj. izračunavanje obilježja za svaki piksel, koja ujedno i predstavlja srednju vrijednost njegove okoline, provodi se operacijom konvolucije. Konvolucija se izvodi između prethodno dobivenog Gaussa i originalne slike.

$$NPF(x, y) = I(x, y) * G(x, y) \quad (2)$$

gdje $I(x, y)$ predstavlja i -ti piksel originalne slike na koordinatama x i y , a operator " $*$ " predstavlja operaciju konvolucije.

Funkcija "NiskoPropusniFilter1" kao argument uzima originalnu sliku, dimenziju i parametar sigma od Gaussove funkcije. Dimenzija bi u idealnom slučaju trebala biti beskonačna, ali se dobra aproksimacija postiže već kod relativno malih brojeva (50 - 100). Sigma je osnovni ulazni parametar o kojem direktno ovisi intenzitet filtra. Njegovom varijacijom mijenjamo opseg regije oko piksela koji se usrednjava. Kao primjer djelovanja ove funkcije uz različite ulazne parametre (sigme), dobiva se rezultat prikazan slikom 4. Na slici 4 su prikazane filtrirane slike slike 3 i to s različitim ulaznim parametrima sigma (0,5, 2, 3,5 i 5 gledano slijeva nadesno).

b) Obilježje piksela realiziranog pomoći Laplacian of Gaussian operatora (LOG)

Linije koda funkcije "ExtractFeatures" od (7)-(9) i (18)-(20) definiraju ovu akciju. Kao i u prethodnom slučaju,

prvo se vrši izračunavanje obilježja, a nakon toga obilježja se spremaju u polje obilježja u za njih predviđeno mjesto.

I ovdje je dimenzija obilježja uz konstantan ulazni parametar jednak dimenziji slike. Stoga se zbroj obilježja uz određeni parametar može slikovito prikazati. Kod izračunavanja obilježja poziva se funkcija "Laplacian_of_Gaussian". Ta funkcija je implementira LOG (Laplacian of Gaussian) operator. I ovaj put se izvodi konvolucija, ali sada između operiranog "Gaussa" s "Laplaceom" i slike.

- (1) %nisko propusni filter; Laplacian_of_Gaussian!
- (2) function LOG = Laplacian_of_Gaussian (slika, dim, sigma)
- (3) filt= fspecial('gaussian', dim, sigma);
- (4) flog= del2(filt);
- (5) LOG= conv2(slika, flog, 'same');

Dakle, razlika koda funkcije "Laplacian of Gaussian" od "NiskoPropusni Filter1" je u liniji (4). Prije same konvolucije Gausova funkcija od dvije varijable je podvrgnuta Laplaceovim operatorom, i nakon toga ide sama konvolucija. Za Laplaceov operator u (4) korištena je ugrađena MatLab funkcija, koja je isto tako dosta gruba diskretna aproksimacija originalne, ali za naš slučaj dovoljna. Definicija LOG-a matematički zapisana kao

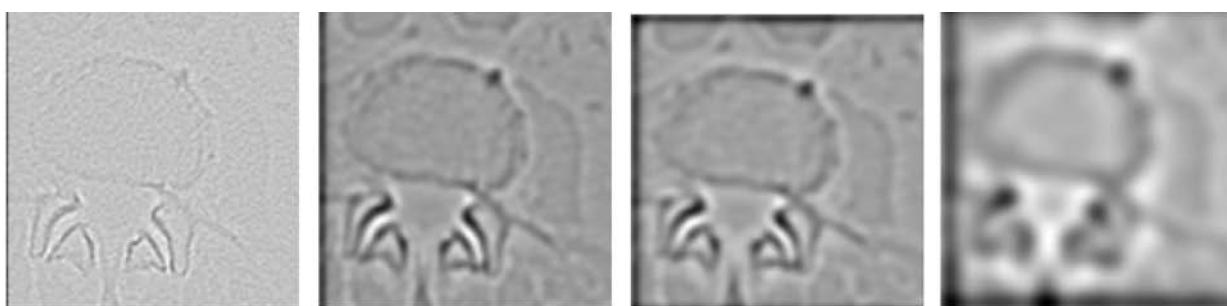
$$LOG(x, y) = \nabla^2(I(x, y) * G(x, y)) \quad (3)$$

$$LOG(x, y) = I(x, y) * \nabla^2 G(x, y) \quad (4)$$

gdje, $I(x, y)$ kao i prije predstavlja piksel slike na koordinatama x, y ; $G(x, y)$ je Gaussova funkcija od dvije varijable, a ∇^2 predstavlja Laplaceov operator.

Naredba pod (5) realizira konvoluciju pomoću ugrađene funkcije MatLab-a. Funkcija "Laplacian_of_Gaussian" kao argument uzima originalnu sliku, dimenziju i parametar sigma od "Gaussa".

Ova funkcija kao rezultat filtriranja (izdvajanja obilježja), kada se slikovito prikaže, ističe konture (rubove) u slici.



*Slika 5 Izdvajanje obilježja slike pomoći LOG operatara
Figure 5 The image feature extraction using LOG operator*

Sigma kao parametar je osnovni ulazni parametar o kojem direktno ovisi intenzitet filtra. Njegovom varijacijom mijenjamo opseg i intenzitet kontura u slici. Kao primjer djelovanja ove funkcije uz različite ulazne parametre (sigme), dobivaju se rezultati prikazani slikom 5. Na slici 5 su prikazane filtrirane slike 3. i to s različitim ulaznim parametrima sigma (0,5, 2, 3,5 I 5).

3

Segmentacija slike pomoću samo-organizirajućih neuronskih mreža

Segmentation of the image using self-organizing neural network

Slika 6. prikazuje rad algoritma po kojem se vrši segmentacija. Prvo se iz slike čitaju podatci (pixeli), nakon čega se izdvajaju obilježja. Tako dobivena obilježja predstavljaju ulaz u samo-organizirajuću neuronsku mrežu. Nakon što se mreža naučila (istrenirala), svaki piksel se stavlja na ulaz mreže i grupira u jednu od fiksнog broja regija. Funkcija koja realizira segmentaciju je "Segmentation":

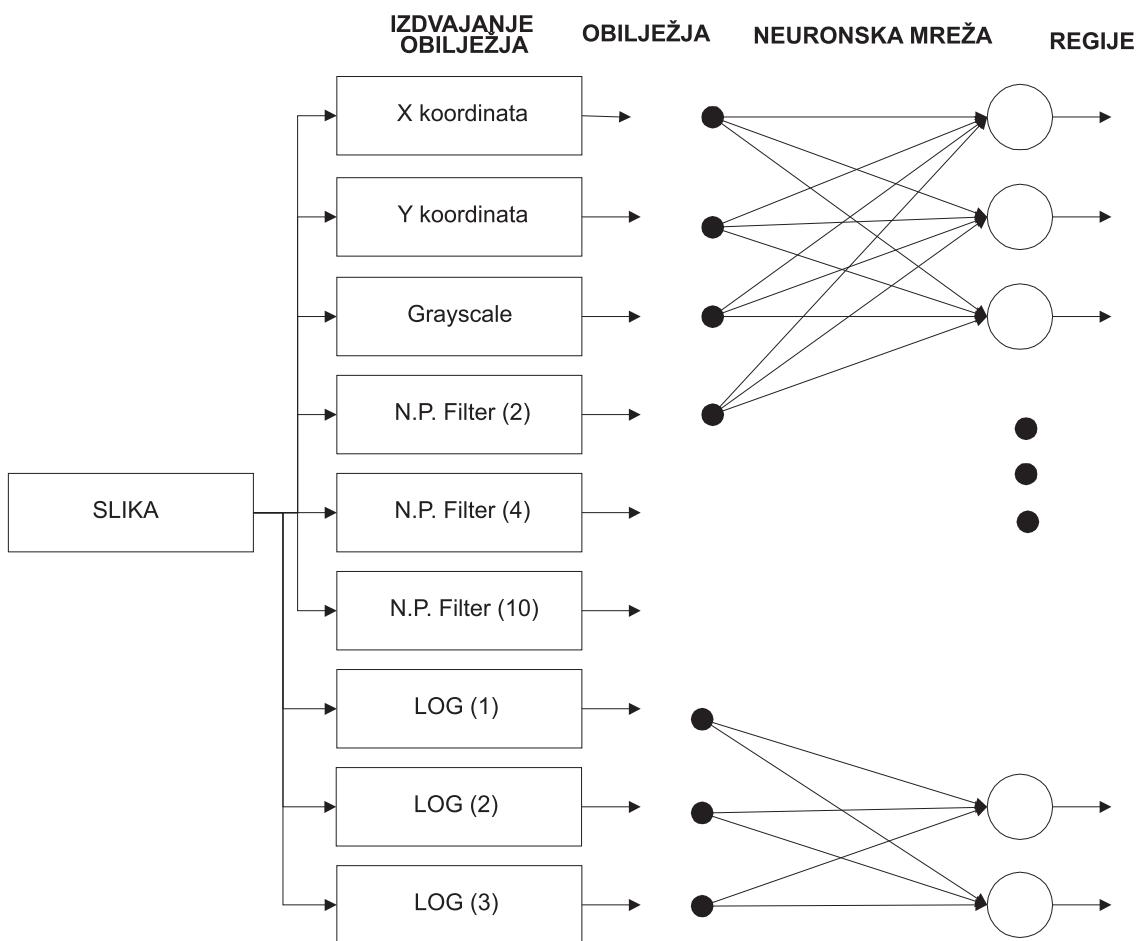
- (1) %segmetira sliku
- (2) %S - ime datoteke
- (3) %N - broj segmenata
- (4) %M = [A B C] - parametri učenja
- (5) %A - broj svakih koliko epoha da se iscrtava rezultat
- (6) %B - broj iteracija

```

(7) %C - konstanta učenja
(8) function S=Segmentation(Slika,N, M, dim)
(9) warning off Images:genericDICOM
(10) NNTWARN OFF
(11) %X = double(dicomread(Slika));
(12) X = double(Slika);
(13) F=ExtractFeatures(X, dim);
(14) w = initc(F, N);
(15) w = trainc(w, F, M);
(16) S = double(zeros(size(X,1), size(X, 2)));
(17) for i=1:size(X, 1)
(18)   for j=1:size(X,2)
(19)     p = F(:, (i-1)*size(X, 1) + j);
(20)     [S(i, j), b, g] = find(simuc(p, w));
(21)   end
(22) end
(23) for i=1:size(X, 1)
(24)   for j=1:size(X,2)
(25)     if S(i, j) ~= 1
(26)       S(i, j) = S(i, j) + N/4;
(27)     end
(28)   end
(29) end
(30) imshow(S, []);

```

U (13) se poziva funkcija "ExtractFeatures" koja kao parametar predaje CT-sliku i dimenziju koja će aproksimirati Gaussovnu funkciju. Nakon toga se pomoću (14) i (15) inicira i uči samo-organizirajuća mreža pomoću ugrađenih MatLab-ovih funkcija.



*Slika 6 Postupak segmentacije slike
Figure 6 The image segmentation process*

4**Iscrtavanje****Drawing**

Ovaj dio algoritma realizira se naredbama (17)-(29). U (17)-(22) traži se odziv od istrenirane mreže za svaki piksel ponaosob. Nakon što mreža dobije kao ulaz vrijednost piksela, ona kao izlaz daje cijeli broj, koji označava redni broj grupe u koju je piksel svrstan. Broj grupa zadaje se kao ulazni parametar glavne funkcije "Segmentation" u liniji (8). Linije koda (23)-(29) su orijentirane samo na označavanje. Označavanje je realizirano vrlo jednostavno. Ono direktno ovisi o broju regija (segmenata). U svrhu označavanja konstruirali smo novu sliku jednakih dimenzija kao i originalna. A vrijednost piksela u toj novoj slici odgovara odzivu originalnog piksela na istreniranu mrežu. Dakle svaki piksel pripada jednu od N vrijednosti, gdje je N broj grupa u ulaznom parametru glavne funkcije. Pošto je nijanse crne boje i njihove razlike (niže vrijednosti grayscale-a) teže uočiti, linije koda (23)-(29) pomiču skalu za jednu četvrtinu prema svjetlijim nijansama. Naravno da u originalnoj slici, ako je npr. pozadina crna, ne mora nužno značiti da će se nakon segmentacije i označavanja, baš za tu grupu dobiti niži indeks (jer niži indeks u grayscale-u povlači i tamniju boju).

5**Rezultati****Results**

Ulagana funkcija dana je slikom 3. Aplikacija se pokreće naredbom (5):

$$\text{izlaz} = \text{Segmentation}(\text{ulaz}, \text{br_regija}, [\text{A} \text{ } \text{B} \text{ } \text{C}], \text{dim}) \quad (5)$$

ulaz - predstavlja originalnu CT-sliku

izlaz - je segmentirana i označena slika originalne slike

br_regija - predstavlja broj segmenata na koliko će se slika podijeliti (2 - 30)

A, B, C - interni parametri MatLab-ove funkcije za treniranje mreže

A - broj iteracija prije iscrtavanja (100)

B - broj epoha učenja (5000 - 20000)

C - konstanta učenja (0,001 - 0,1)

dim - predstavlja dimenziju matrice proksimiranog "Gaussa" (30-150)

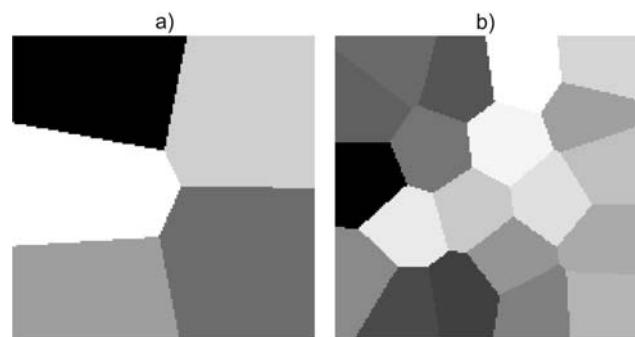
5.1**Učenje mreže****Training of the network**

Slika 7 predstavlja odziv na funkciju segmentacije uz koordinate kao jedino obilježje. Na slići 7a broj postavljenih regija je 5, a na slići 7b je 20.

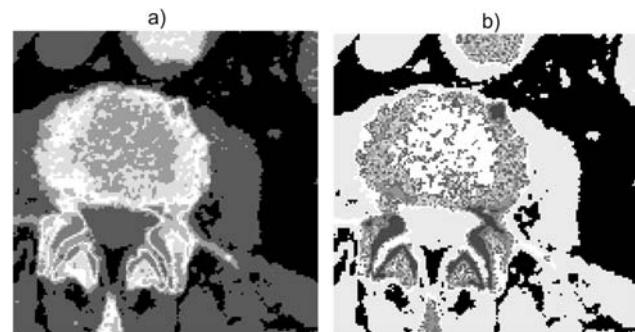
Slika 8 predstavlja odziv na ulagnu funkciju (slika broj 3) s različitim brojem regija 7 i 20.

5.2**Odziv mreže uz primjenu obilježja****Results of the filtering by applying features**

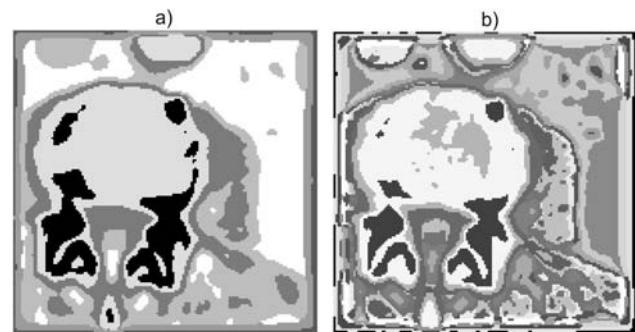
Slika 9 predstavlja odziv mreže na ulagnu funkciju (slika 3), a glavno obilježje je usrednjena vrijednost piksela iz ulagne slike. Broj postavljenih regija za sliku 9a je 7, a za sliku 9b je 20.



*Slika 7 Odziv na funkciju segmentacije uz koordinate kao obilježje
Figure 7 Results of the filtering using coordinates as a feature*



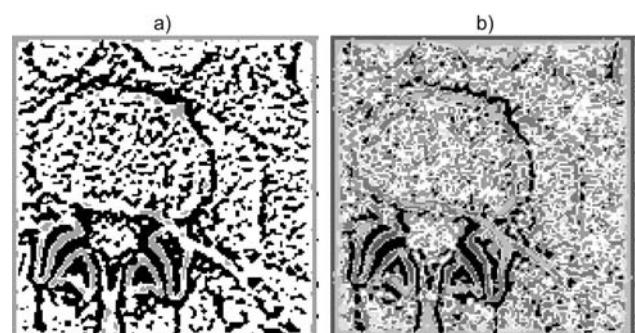
*Slika 8 Odziv na ulagnu sliku
Figure 8 Results of the filtering applied on source image*



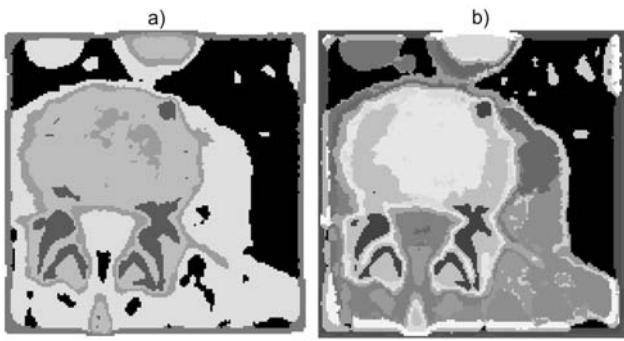
*Slika 9 Odziv mreže na nisko propusni filter
Figure 9 Results of the filtering using low pas filter*

Na slici 10 dan je odziv mreže uz primjenu LOG filtra kao obilježja. Slika 10a predstavlja odziv na ulagnu funkciju (slika 3) s brojem postavljenih regija 3, a slika 10b s brojem postavljenih regija 7.

Na slici 11 dan je odziv mreže uz primjenu svih obilježja. Ukupno su korištene tri grupe, s devet pojedinačnih. Na slici 11a broj regija je 7, a na 11b broj regija je 17. Broj epoha postavljen je na 15000, a konstanta učenja 0,01.



*Slika 10 Odziv mreže na LOG filter
Figure 10 Results of the filtering using LOG filter*



*Slika 11 Odziv mreže uz primjenu svih obilježja
Figure 11 Results of the filtering using all features*

6

Zaključak

Conclusion

U radu je prikazana tehnika obrade slike preuzimanjem podataka iz CT slike koristeći samo-organizirajuće neuronske mreže. Za samoorganiziranje regija CT slike korištene su MatLab funkcije u relativno gruboj diskretnoj aproksimaciji (dim. matrice je 50) koja se pokazala zadovoljavajućom na primjeru. U radu je prikazan postupak učenja neuronske mreže uz konstantu 0,01, provedenu uz 100 iteracija i na 15000 epoha. Dobiveni rezultati u radu pokazuju da se metoda sa zadovoljavajućom kvalitetom može koristiti za analizu i obradu slika. Sustav obrade slika može se koristiti za razmjenu podataka tijekom kirurških zahvata, uključujući i pacijentove vitalne znakove tijekom terapije. Na taj način bi se kirurški zahvati mogli izvoditi uz pomoć i internetski konzalting eksperata.

7

Literatura

References

- [1] Ristić-Durrant, D.; Gräser, A. Closed-Loop Control of Segmented Image Quality for Improvement of Digital Image Processing. // Facta Universitatis Series: Automatic Control and Robotics Vol. 7, 1(2008), str. 27–34
- [2] Vincent, C.; Ghassan, H. MatLab-ITK interface for medical image filtering, segmentation, and registration. // Medical Imaging 2006: Image Processing, Ed. Reinhardt, Joseph M.; Pluim, Josien P. W. / Proceedings of the SPIE, Volume 6144, (2006) str. 1220-1227.
- [3] He, Y.; Pan, J.; Zhang, Y. 3CCD image segmentation and edge detection based on MatLab. // Journal progress in biomedical optics and imaging, Vol. 7(1), 37(2005), str. R.1-R.7
- [3] Ahmed, M. N.; Farag, A. A. 3D Segmentation and labeling using self-organizing Kohonen network for volumetric measurements on brain CT imaging. // ANNIE'96, Umjetne neuronske mreže u inženjerstvu, 1996., str. 1-15.

Adrese autora

Authors' Address

Marko Martinović

Veleučilište u Slavonskom Brodu
Trg S. Miletića 12
35000 Slavonski Brod, Hrvatska

Antun Stoić

Veleučilište u Slavonskom Brodu
Trg S. Miletića 12
35000 Slavonski Brod, Hrvatska

Darko Kiš

Poljoprivredni fakultet
Trg Sv.Trojstva 3
31000 Osijek, Hrvatska