

Razpoznavanje objektov iz zaporedja slik s postopki predikcije

Božidar Potočnik

Univerza v Mariboru
Fakulteta za elektrotehniko, računalništvo in informatiko

Vsebina doktorske disertacije:

1. Uvod
2. Metode za analizo zaporedij slik
3. Razpoznavanje objektov v statičnih 2D slikah
4. Razpoznavanje objektov s postopki predikcije
5. Pregled rezultatov in razprava
6. Sklep

1. Uvod

- V delu se ukvarjali z razpoznavanjem objektov iz zaporedja slik
- Metode obdelave in analize v zaporedju slik že dobro zastopane:
 - Skupne omejitve (konstantno ozadje, objekti se gibljejo podobno)

Zadana naloga:

- Avtomatsko razpoznavanje
- O zaporedju ni na voljo nikakršnih vnaprejšnjih informacij
- Spremembe od slike do slike so lahko tudi velike
- Slediti vsem objektom v sliki

Teza:

Razpoznavanje na osnovi modela, zgrajenega v odvisnosti od področja problema in tipa slik, ki ga pri razpoznavanju iterativno modificiramo skozi zaporedje 2D posnetkov, je optimalno.

Nadgradnja osnovnega postopka s postopki predikcije bistveno izboljša uspešnost in natančnost razpoznavanja.

2. Metode za analizo zaporedij slik

- Metode za analizo gibanja v slikah – optični pretok
- Segmentacijske metode na osnovi gibanja
- Aktivne krivulje – kače
- Tehnike pri 3D slikah
- Metode prediktor-korektor – Kalmanov filter

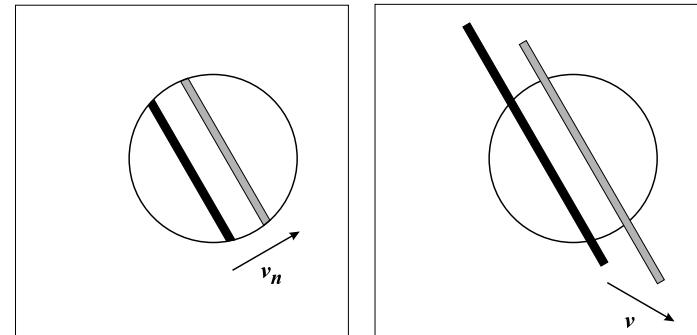
2.1 Metode za analizo gibanja v slikah – optični pretok

Optični pretok $\mathbf{u} \rightarrow$ približek dejanskega 2D polja gibanja \mathbf{v} .

- Diferencialne tehnike – zveznost optičnega pretoka

Enačba konstantne svetlosti:

$$\begin{aligned}\frac{dI}{dt} &= \frac{\partial I}{\partial x} \frac{dx}{dt} + \frac{\partial I}{\partial y} \frac{dy}{dt} + \frac{\partial I}{\partial t} \\ &= (\nabla I)^T \cdot \mathbf{v} + I_t = 0\end{aligned}$$



Problem reže

- Korelacijske tehnike
 - Določiti ustrezne značilke
 - Poiskati pripadajoče točke v sosednjih slikah in določiti premik

2.2 Segmentacijske metode na osnovi gibanja

Cilj: Poiskati regije, ki ustrezano različnim gibajočim se objektom.

Postopek:

1. Transformirati sliko sivin iz zaporedja glede na ustrezeno mero gibanja:
 - Slika razlik \longleftrightarrow statično ozadje
 - Slika robov gibanja
 - Optični pretok
2. Uporabiti ustrezeno segmentacijsko metodo (pragovna operacija, segmentacija na osnovi robov, rast regij)

2.3 Aktivne krivulje – kače

- Kača → zlepek, ki spreminja obliko in lego z zaporednim minimiziranjem energijskega funkcionala
- Energijski funkcional:

$$E_{kače} = \int_{kače} [E_{not}(s(t)) + E_{zun}(s(t))] dt$$

- Uporaba pri obdelavi zaporedij slik:
 1. Določiti dober začetni približek objekta v prvi sliki
 2. Segmentacija s kačami
 3. Rezultat na trenutni sliki uporabiti kot začetni približek v naslednji sliki

2.4 Tehnike pri 3D slikah

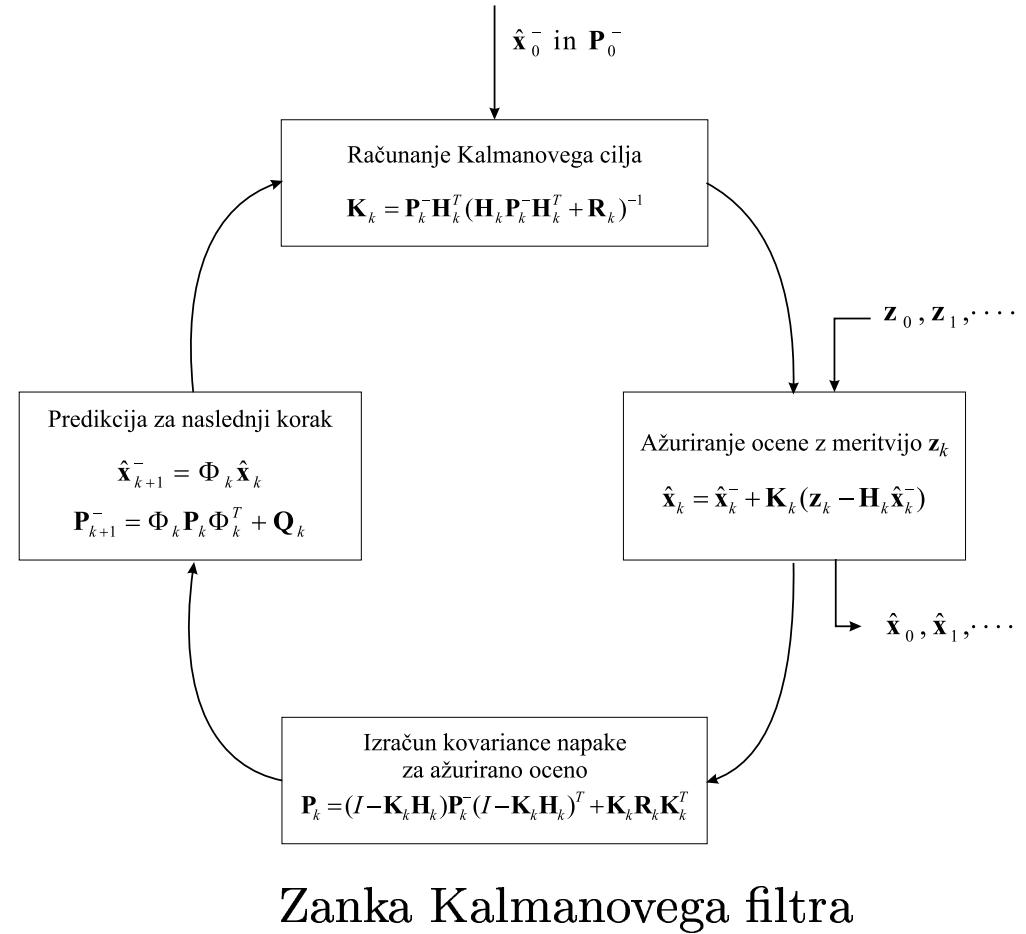
- 3D slika → blok sestavljen iz zaporedja 2D prerezov (voksel)
- Različne metode obdelovanja 3D slik:
 - 3D detektorji robov
 - 3D segmentacijske metode
 - 3D rekonstrukcija
 - Metode za analizo gibanja

2.5 Metode prediktor-korektor – Kalmanov filter

- Vključiti zgodovino razpoznavanja
- Kalmanov filter → optimalni rekurzivni filter za obdelavo podatkov
- KF avtomatsko prilagaja parametre glede na statistiko meritev

Enačbi sistema:

$$\begin{aligned}\mathbf{x}_{k+1} &= \Phi_k \mathbf{x}_k + \mathbf{w}_k \\ \mathbf{z}_k &= \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k\end{aligned}$$



Kalmanov filter pri obdelovanju zaporedja slik

- Uporaba za sledenje objektom v zaporedju slik – korelacijske tehnike
- Osnovna varianta sledenja s KF:
 1. Ciljni objekt aproksimiramo s težiščem
 2. Informacije o premikanju težišča vgradimo v KF
 3. V stanju sistema hranimo koordinati težišča (x in y) ter odmika (Δx in Δy)
 4. Na osnovi predikcije $\Phi \hat{\mathbf{x}}_k$ predvidimo položaj težišča v naslednji sliki (krčenje območja preiskovanja)

3. Razpoznavanje objektov v statičnih 2D slikah

- Predstavili nov algoritem za razpoznavanje objektov na statični 2D sliki.
- Algoritem splošen in neodvisen od tipa slik:
 - uporabljena predpostavka: objekti temnejši od svoje okolice
- Uspešnost merili na umetnih in realnih ultrazvočnih posnetkih jajčnikov z mešički:
 - izbira domene vpliva na določitev parametrov algoritma

3.1 Ultrazvočne slike in jajčni mešički

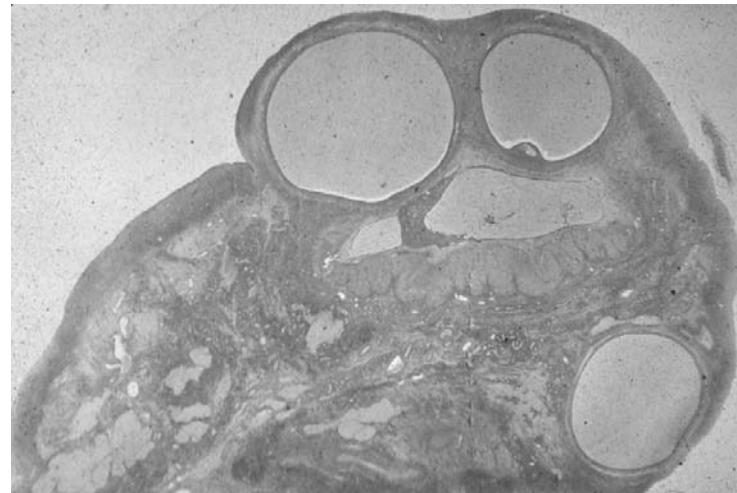
- Ultrazvok je eno najpomembnejših orodij medicine.
- Objektivne omejitve ultrazvoka (odboj, subjektivnost pregleda, šum).
- Problem verificiranja – rezultati ekspertov edino merilo.
- Računalniški postopki za razpoznavanje jajčnih mešičkov so redki in nezadovoljivi.



Ultrazvočni posnetek
jajčnika z mešički

3.2 Simulator za tvorjenje fantomov jajčnikov

- Jajčnik:
 - ovalen, ploščat, belkast in neravne površine
 - velikosti [2, 2; 5, 2 cm] x [1, 5; 2, 0 cm] x [1, 5; 3, 0 cm]
- Strukture znotraj jajčnika:
 - mešički (ovalni, velikosti od 8 do 10 mm, zreli od 17 do 25 mm)
 - krvne žile
 - živčne niti
 - mezgovnice

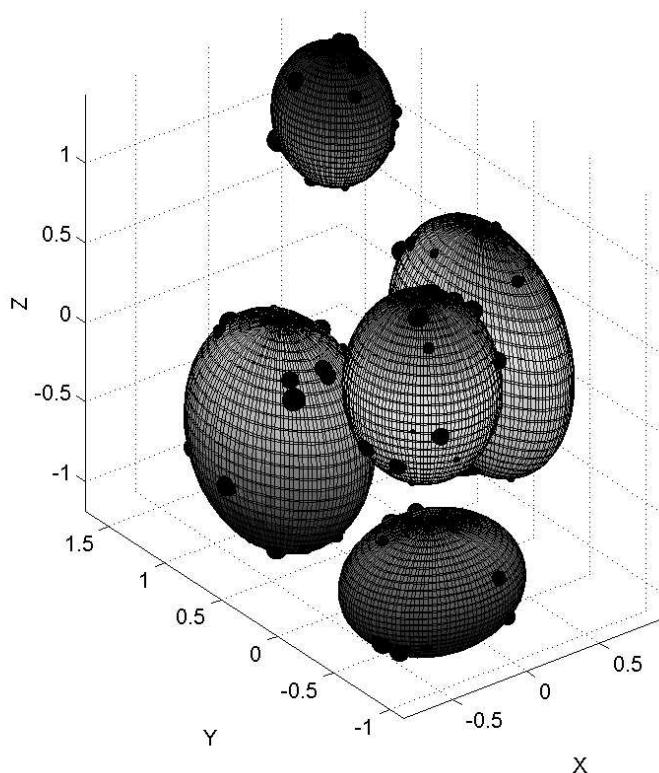


Model jajčnika z mešički

- Jajčnik modeliran kot kvader velikosti 4 x 2 x 3 cm.
- Mešički aproksimirani z elipsoidi:

$$\frac{(x - x_0)^2}{a_2} + \frac{(y - y_0)^2}{b_2} + \frac{(z - z_0)^2}{c_2} = 1$$

- Parametri a , b in c ter položaj določeni naključno
- Mešički se ne prekrivajo niti ne dotikajo
- Na površino mešičkov dodani majhni izrastki (majhne krogle)



Primer jajčnika:

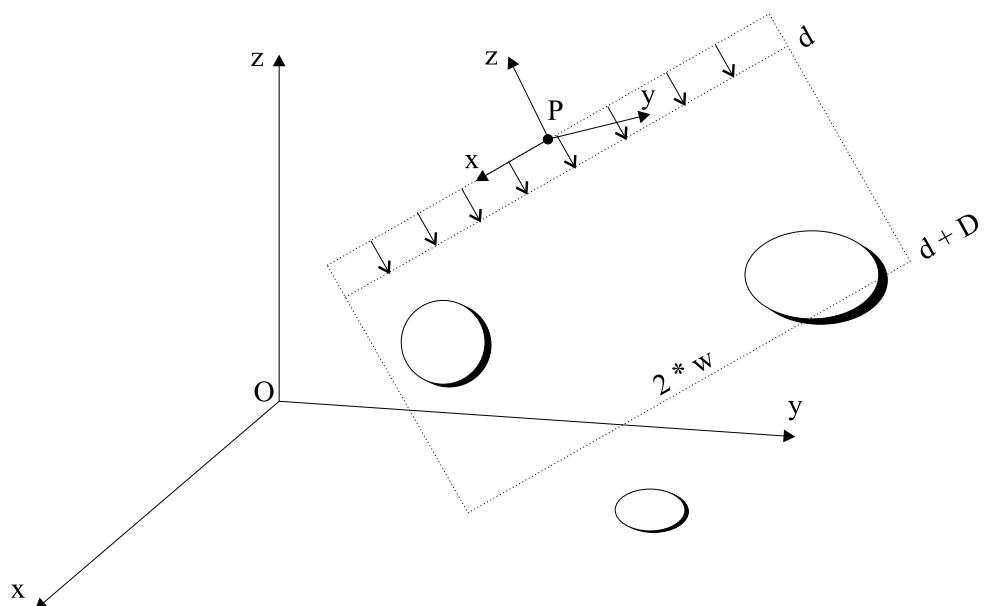
- Model diskretizirali z natančnostjo 0,1 mm
- Jajčnik v matriki 3D z dimenzijami 400 x 200 x 300 točk

⇒ Modelirane jajčnike pregledujemo z ultrazvočno sondou.

Model ultrazvočne sonde

Tvorjenje prerezov:

- Umestimo in rotiramo sondu
- Režemo z XZ ravnino sonde
- Upoštevamo fizikalne omejitve ultrazvoka

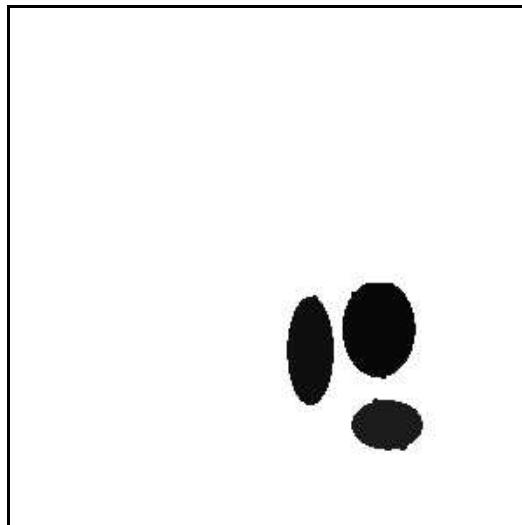


Dodajanje efekta ultrazvoka:

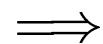
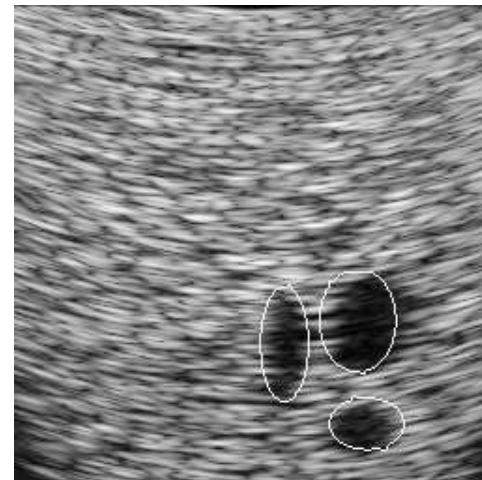
- Program Field
- Sistem: linearno polje pretvornikov (24), centralna frekvenca 3 MHz, fiksen fokus (70 mm), 128 linij pregledovanja
- 4000 točk, ki raztresajo ultrazvok. Amplitude točk določene iz prerezov.

3. Razpoznavanje objektov v statičnih 2D slikah

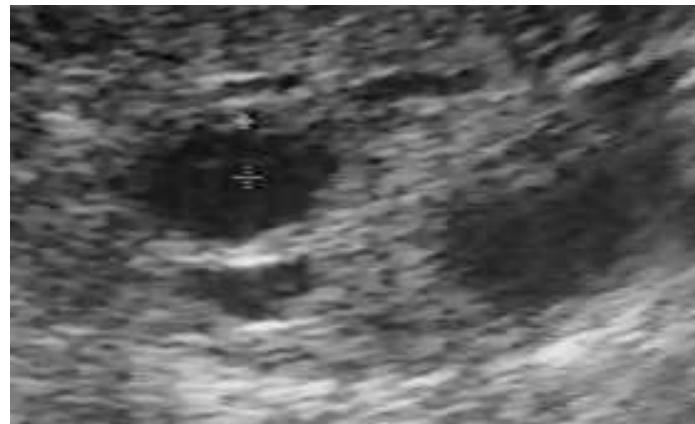
Prerez skozi jajčnik



Fantom jajčnika



Realen posnetek



3.3 Razpoznavanje mešičkov v ultrazvočnih slikah jajčnikov

- Nov algoritem → razpoznavanje mešičke na posamezni 2D sliki
- Lastnosti mešičkov v ultrazvočnih posnetkih:
 - Sferične strukture, napolnjene s tekočino
 - V slikah kot temne ovalne strukture
 - Šibki in nevezni robovi mešičkov
 - Podobna odmevna tekstura tekočine – temnejša kot okolica:
 - Mešički homogene regije

Ideja: Poiskati homogene regije ter jih privesti do pravega roba objekta.

Algoritem

1. Določanje homogenih regij

Sivine

- $Filt = \text{DvakratGladi}(I_k);$
- $Pomozna = Filt \leq T_2;$
- $Hom_1 = \text{BinarnoRazvodje}(Pomozna);$

Standardni odklon

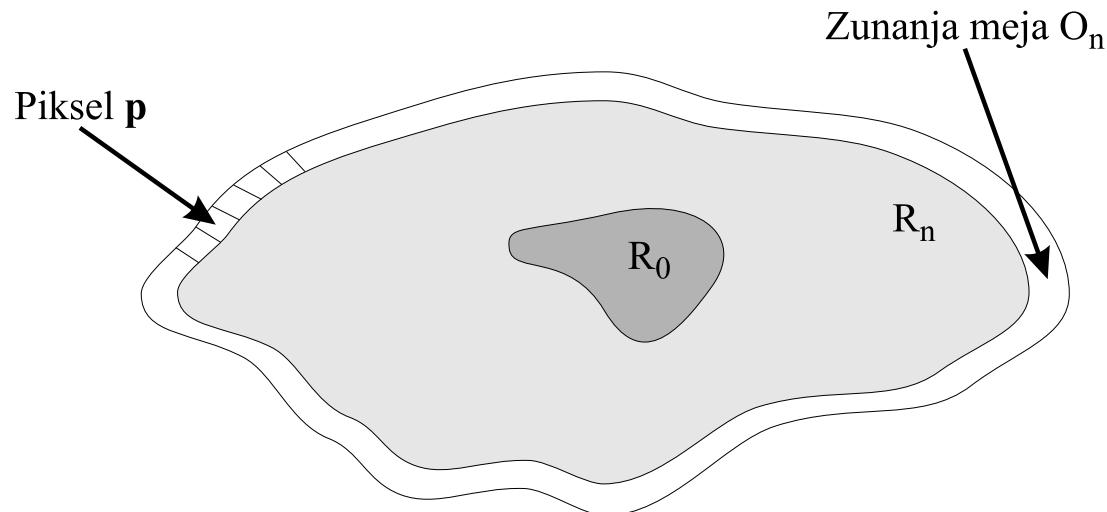
- $Pomozna = \sigma(I_k);$
- $Hom_2 = (Pomozna \leq T_3) \wedge (I_k \leq T_1);$



- $Hom = Hom_1 \vee Hom_2;$
- Odstrani vse regije v Hom : a) imajo ploščino $\leq T_4$,
b) se dotikajo roba slike;
- Označi preostale regije.

Algoritem

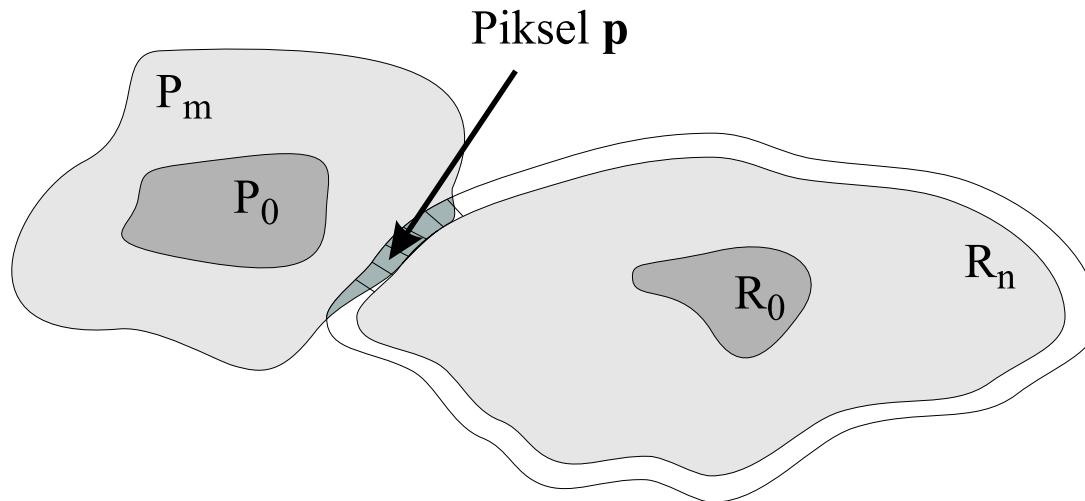
2. Rast regij



Piksle $\mathbf{p} \in O_n$ je potencialni kandidat za zlitje:

1. $|I_k(\mathbf{p}) - m(R_0)| \leq \alpha \sigma(R_0)$
2. $|grad(\mathbf{p}) - m(grad(R_0))| \leq \alpha \sigma(grad(R_0))$

2. Rast regij



Regiji R_n in P_m zlijemo:

$$\frac{|m(R_0) - m(P_0)|}{\sigma(R_0 \cup P_0)} \leq T_5 \quad \wedge \quad \frac{|m(\text{grad}(R_0)) - m(\text{grad}(P_0))|}{\sigma(\text{grad}(R_0 \cup P_0))} \leq T_5$$

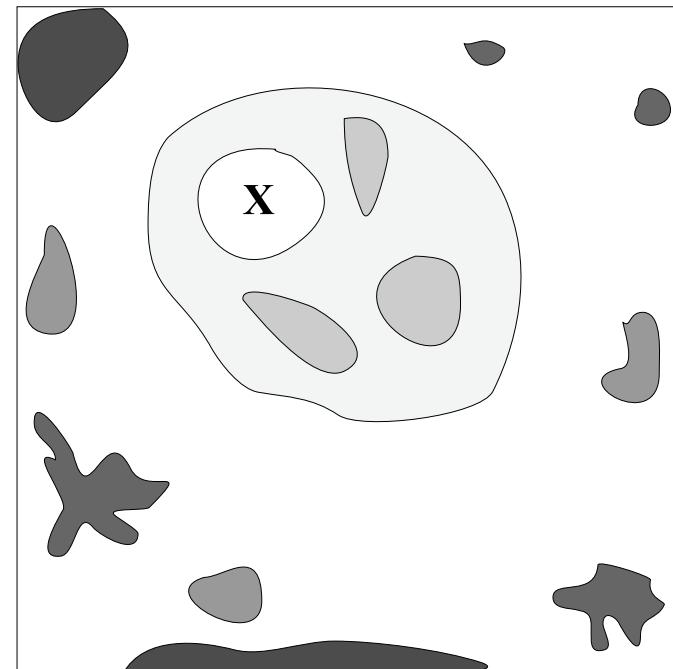
- Člena porazdeljena po Studentovi t porazdelitvi
 → prag T_5 enolično določen z izbiro intervala zaupanja

Algoritem

3. Izločanje mešičkov

Štiri pravila:

1. Odstrani regije, ki se dotikajo meje slike.
2. Odstrani premajhne regije.
3. Odstrani nekompaktne regije.
4. Mešički ležijo skupaj.



Potencialni mešički

3.4 Rezultati razpoznavanja

Testna množica

Umetni ultrazvočni posnetki

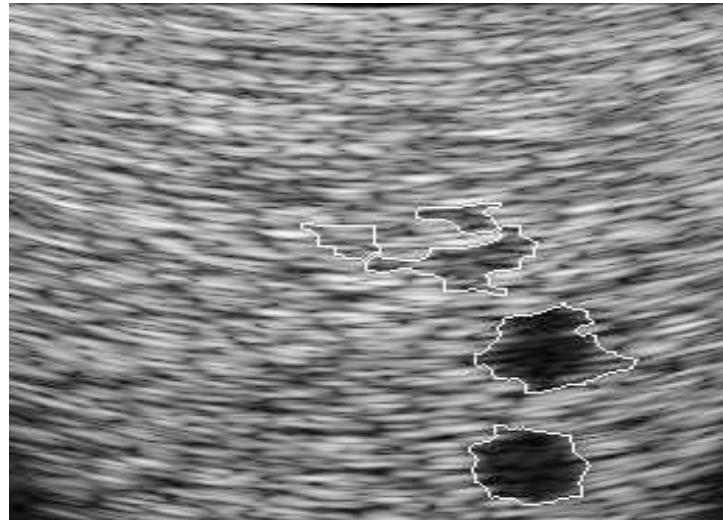
- 120 posnetkov jajčnikov
- velikosti 256 x 256 pikslov v 256 sivinah
- znan točen položaj mešičkov

Realni ultrazvočni posnetki

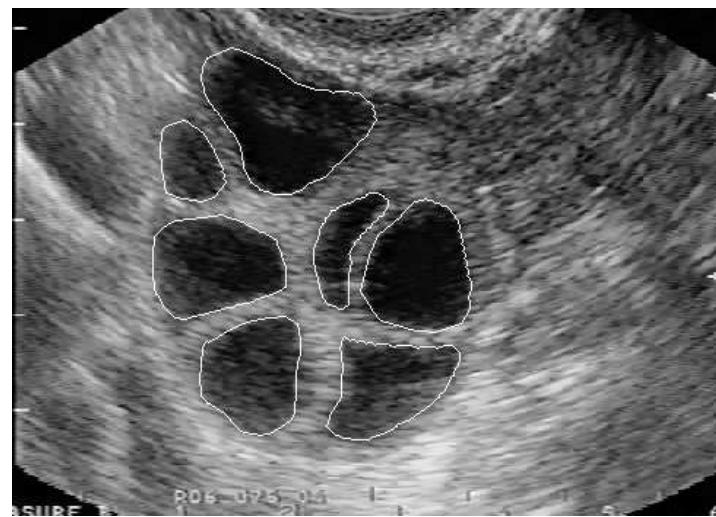
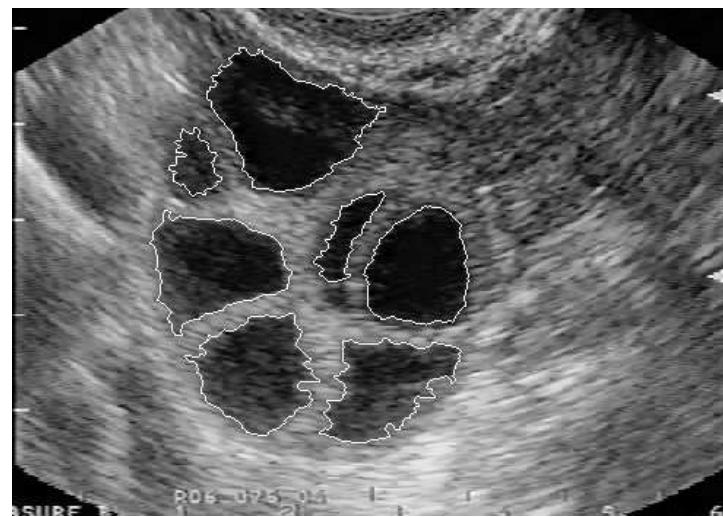
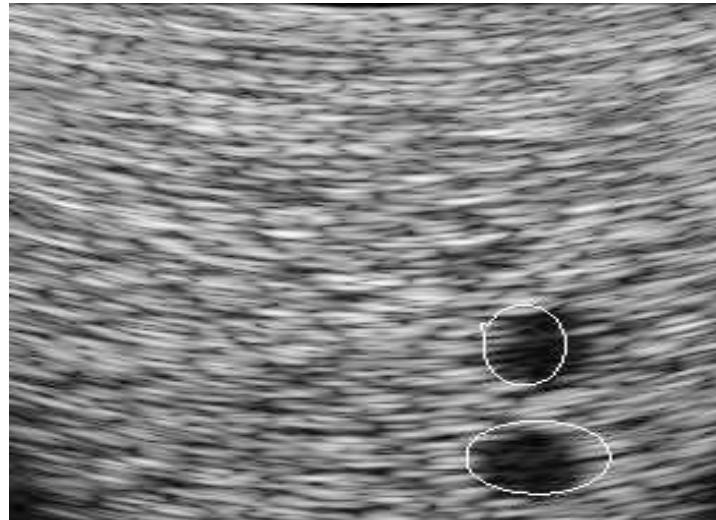
- 50 posnetkov jajčnikov
- velikosti 640 x 480 pikslov v 256 sivinah
- referenčni položaj mešičkov – ocene eksperta

3. Razpoznavanje objektov v statičnih 2D slikah

Razpoznani mešički



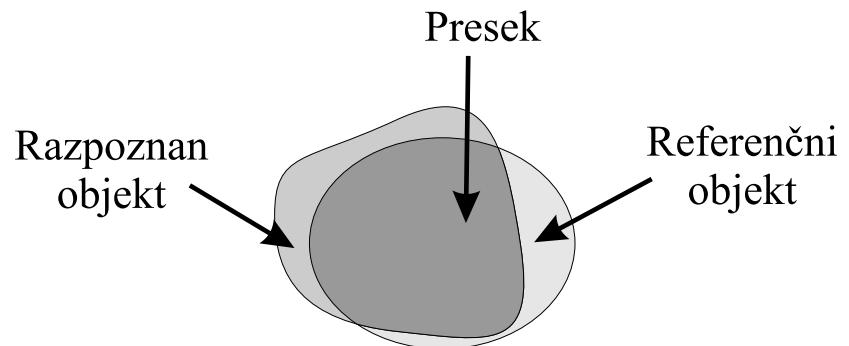
Referenčni položaj



Kvantitativni rezultati učinkovitosti segmentiranja

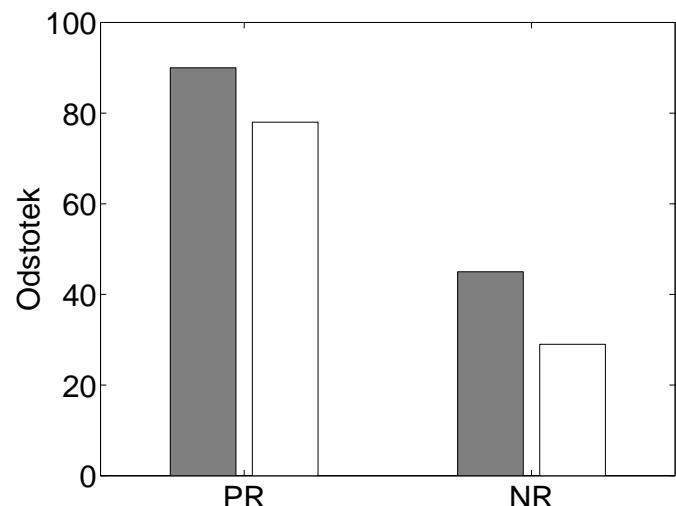
Uporabljene mere:

- Količnika r_1 in r_2
- Odstotek razpoznavanih mešičkov
- Odstotek napačno razpoznavanih mešičkov
- Povprečna absolutna razdalja (modificirana Hausdorffova razdalja)

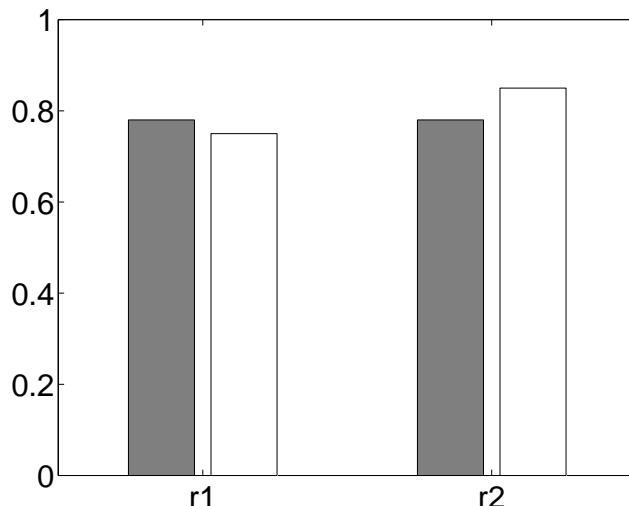


$$r_1 = \frac{p_{\text{pres}}}{p_{\text{ref}}} \quad \text{in} \quad r_2 = \frac{p_{\text{pres}}}{p_{\text{raz}}}$$

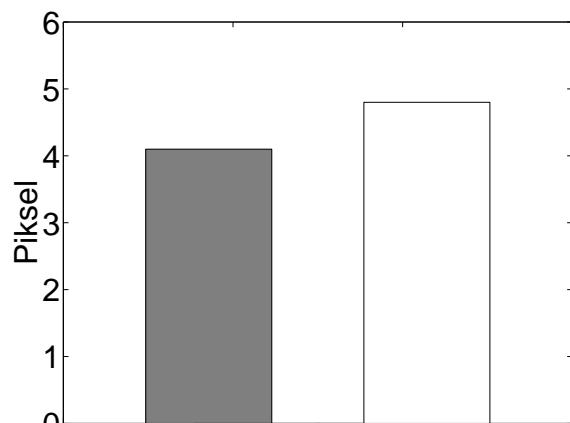
3. Razpoznavanje objektov v statičnih 2D slikah



Odstotek razpoznavanja



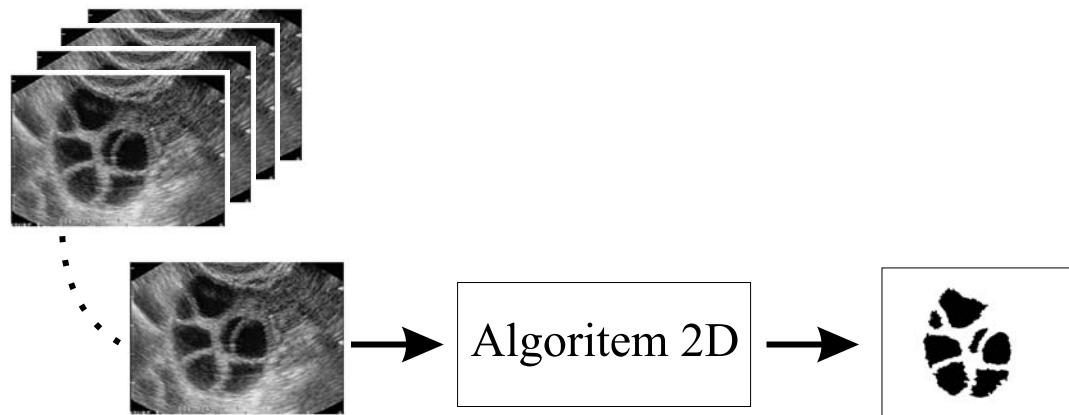
Količnika r_1 in r_2



Povp. absolutna razdalja d

A legend box containing two entries: "Umetni posnetki" represented by a dark gray square and "Realni posnetki" represented by a white square with a black outline.

| | |
|---|-----------------|
| ■ | Umetni posnetki |
| □ | Realni posnetki |



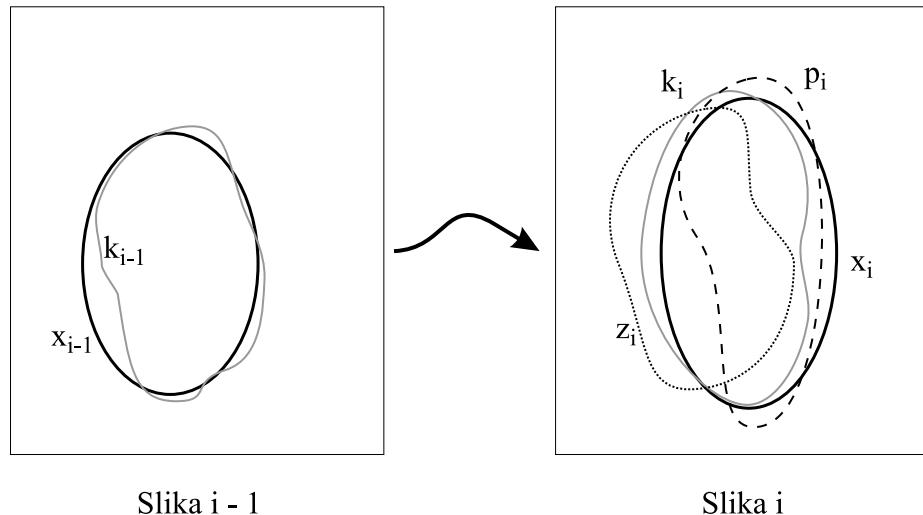
- + Velika uspešnost avtomatskega razpoznavanja mešičkov
- + Ob bok najboljšim algoritmom 2D
- Velik odstotek napačno razpoznanih
- Majhna gotovost v rezultate



Uporabiti zgodovino razpoznavanja v trenutni sliki.

4. Razpoznavanje objektov s postopki predikcije

Definicija problema



predikcija

$$p_i = \mathcal{P}(k_{i-1})$$

najboljši približek objekta

$$k_i = \mathcal{W}(p_i, z_i)$$

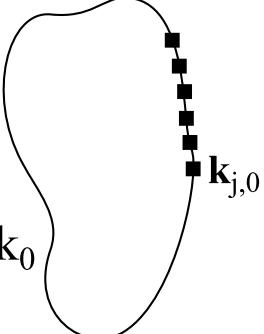
Predpostavki:

1. \mathcal{W} omejena na množico linearnih funkcij
2. meritev z_i in predikcija p_i normalno porazdeljeni okoli dejanskega objekta x_i

⇒ Rezultate predhodnih razpoznavanj vgraditi v Kalmanov filter.

4.1 Osnovna oblika algoritma – globalni Kalmanov filter

Vzpostavljanje začetnega stanja



$$\Rightarrow \hat{\mathbf{x}}_{j,0} = \begin{bmatrix} k_{x_{j,0}} \\ k_{y_{j,0}} \\ 0 \\ 0 \end{bmatrix} \quad \mathbf{P}_{j,0}^- = \begin{bmatrix} 10^3 & 10^3 & 10^3 & 10^3 \\ 10^3 & 10^3 & 10^3 & 10^3 \\ 10^3 & 10^3 & 10^3 & 10^3 \\ 10^3 & 10^3 & 10^3 & 10^3 \end{bmatrix}$$

Slika S_0

Sistem stanj:

$$\mathbf{x}_{j,i} = \underbrace{\begin{bmatrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}}_{\Phi} \cdot \mathbf{x}_{j,i-1} + \mathbf{w}_{i-1} \quad \mathbf{w}_{i-1} \sim N(0, \mathbf{Q}_{i-1})$$

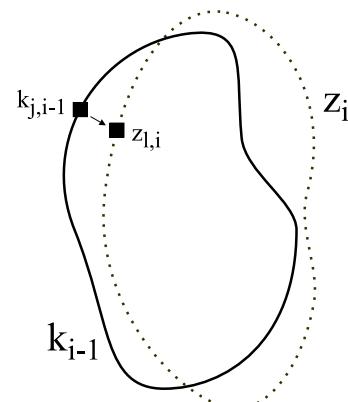
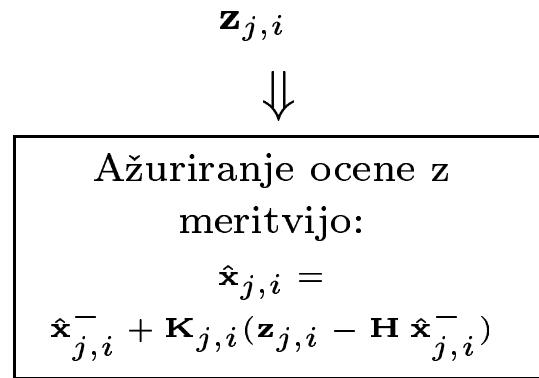
Merilni sistem:

$$\mathbf{z}_{j,i-1} = \underbrace{\begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix}}_{\mathbf{H}} \cdot \mathbf{x}_{j,i-1} + \mathbf{v}_{i-1} \quad \mathbf{v}_{i-1} \sim N(0, \mathbf{R}_{i-1})$$

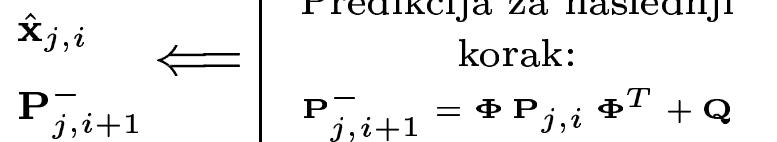
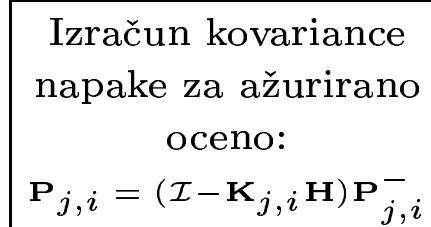
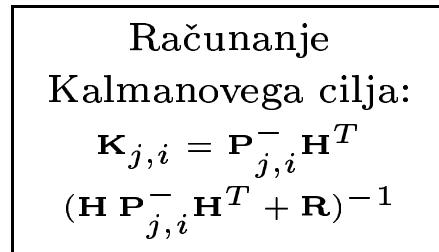
4. Razpoznavanje objektov s postopki predikcije

$$\mathbf{Q} = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

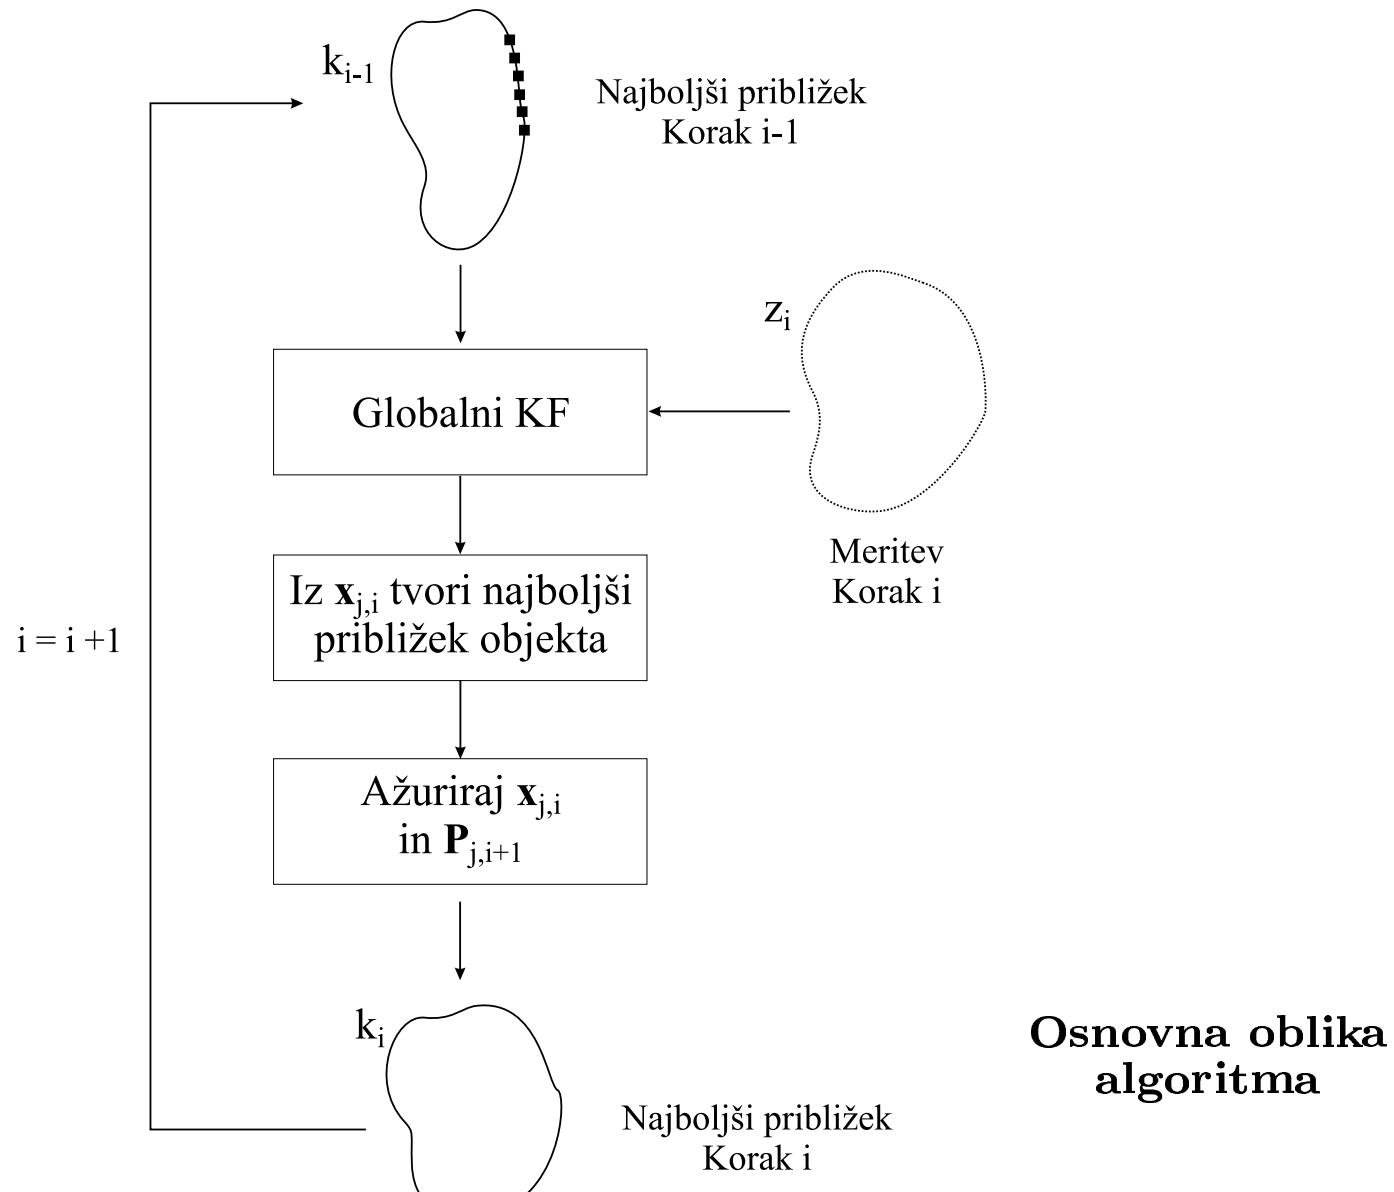
$$\mathbf{R} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$$



$$\begin{matrix} \hat{\mathbf{x}}_{j,i-1} \\ \mathbf{P}_{j,i}^- \\ \mathbf{Q}, \mathbf{R} \end{matrix} \implies$$



**Globalni Kalmanov
filter**

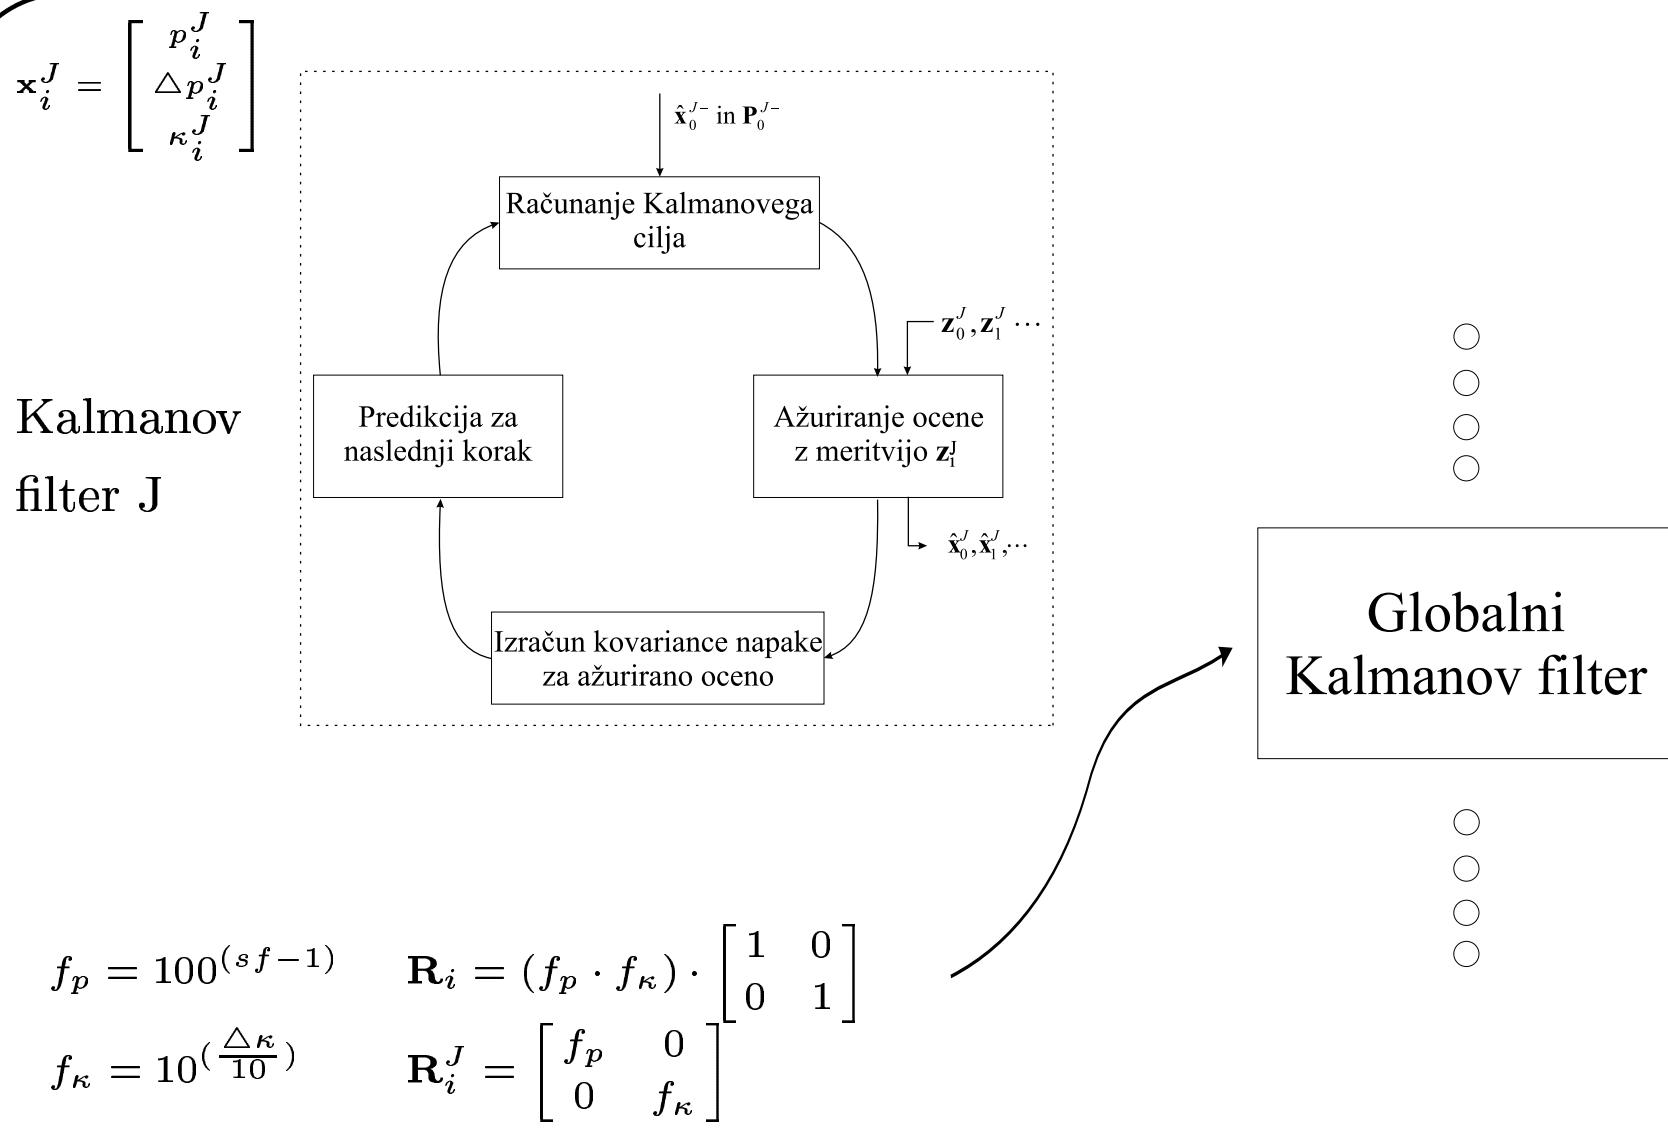


4.2 Problem velikih napak v meritvah – Kalmanov filter J

- Matriki \mathbf{Q} in \mathbf{R} konstantni → konstantna kovariančna matrika \mathbf{P} :
 \Rightarrow ocene KF zreducirane na ocene po metodi najmanjših kvadratov
 (občutljivost na velike napake v podatkih)

Ideja:

- Vsako meritev upoštevati različno (matrika \mathbf{R})
- Vpeljati kriterijsko funkcijo J za ocenjevanje meritev (predvidene vrednosti meritve \Leftrightarrow dejanski meritvi)
- Primer mešičkov – odločitev na osnovi ploščine in kompaknosti
- Predhodne vrednosti meritev vgraditi v Kalmanov filter (KF J)

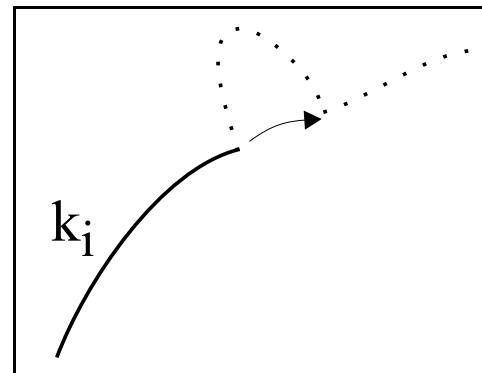


4.3 Lokalnost krivulje – Kalmanov filter LOK

- Vsaki točki s krivulje sledimo neodvisno od drugih:
⇒ ni upoštevana sosednost točk (lokalnost krivulje)

Ideja:

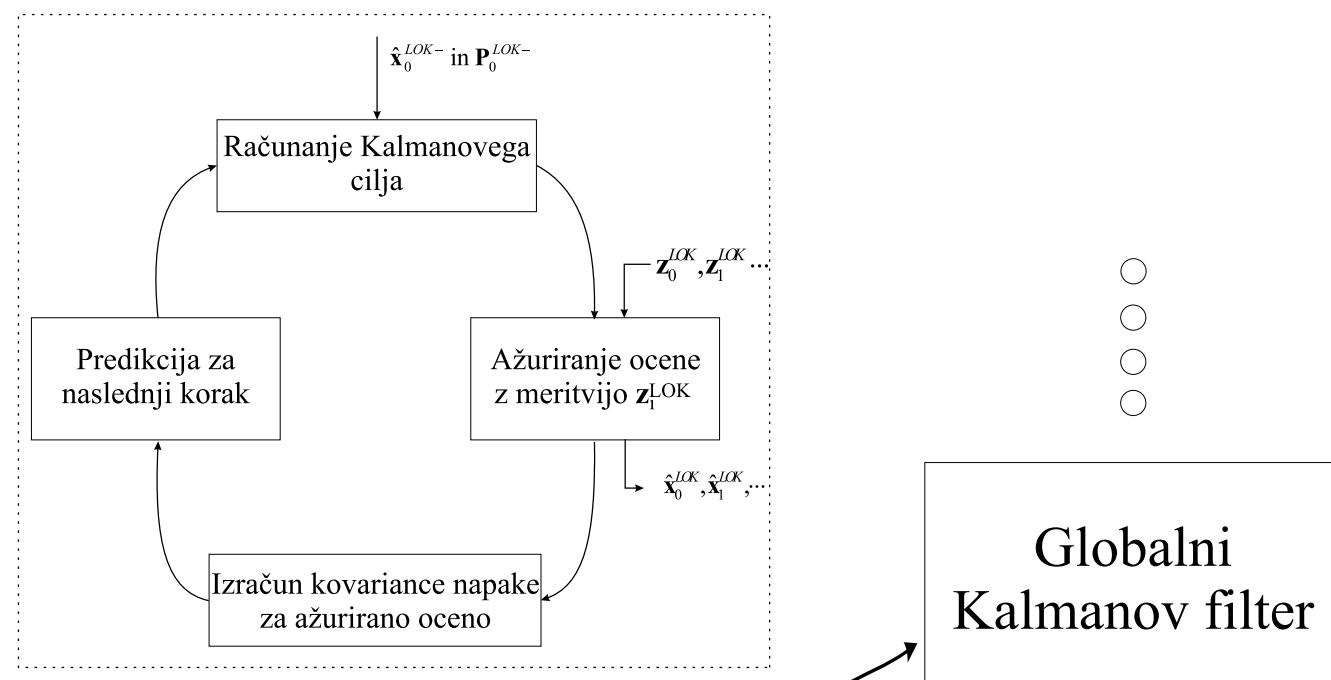
- Vse točke s krivulje nimajo istih lastnosti (ene bližje pravemu položaju) – vpliv na **Q** in **R**
- Vpeljati kriterij za ocenjevanje lokalnosti krivulje (predviden \Leftrightarrow dejanski položaj točke)
- Izvedba s Kalmanovim filtrom (KF LOK)
- Predpostavka: iskani objekti so kompaktni



4. Razpoznavanje objektov s postopki predikcije

$$\mathbf{x}_i^{Lok} = \begin{bmatrix} x_i^{Lok} \\ y_i^{Lok} \\ \Delta x_i^{Lok} \\ \Delta y_i^{Lok} \end{bmatrix}$$

Kalmanov
filter LOK



Globalni
Kalmanov filter

$$\omega = \|\Upsilon_{j,i} - \mathbf{k}_{j,i}\| \quad \mathbf{Q}_{j,i} = \begin{cases} \mathbf{Q}_i, & \text{če } \omega \leq 1 \\ \omega \cdot \mathbf{Q}_i, & \text{sicer} \end{cases}$$

$$\mathbf{R}_{j,i} = \begin{cases} \mathbf{R}_i/\omega, & \text{če } \omega \leq 1 \\ \mathbf{R}_i, & \text{sicer} \end{cases}$$

Dodan KF LOK

4.4 Neustrezna porazdelitev meritev

- Algoritem preizkusili na zaporedju slik z razpoznanimi mešički:
⇒ testne meritve podcenjene → podcenjen tudi najboljši približek objekta (sistemska napaka)

Ideja:

- Modificirati meritve jajčnih mešičkov
- Vgraditi mehanizem, ki zaznava, da je meritve premajhna, in jo zato ustrezno modifica
- Napako $e(z_i, x_i)$ lahko zgolj ocenimo → ocena na osnovi razdalje med približkom objekta k_i in meritve z_i

Izvedba modifikacije meritve jajčnih mešičkov

1. korak: Ali meritev modificiramo?

- Opazujemo ploščino p in povprečno sivino m v regijah z_i in k_i

$$\eta = \begin{cases} 1, & \left(\frac{p(z_i)}{p(k_i)} > (1 - \epsilon_p) \right) \wedge \left(m(z_i) > (m(k_i) - \epsilon_m) \right) \\ 0, & \text{sicer} \end{cases}$$

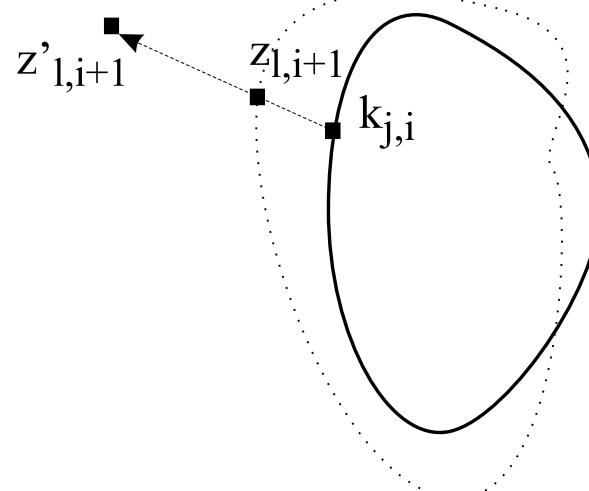
- Izkustven kriterij \rightarrow podobnost z napihovanjem balona
- Hitrost cikla nadzorujemo s parametromi ϵ_p in ϵ_m

2. korak: Modifikacija meritve

- Globalno oceno o velikosti širjenja daje $\|e(z_i, k_i)\|$, točno vrednost določajo lokalne lastnosti točke
- Če točka $\mathbf{z}_{l,i+1}$ blizu pravega položaja \rightarrow točko premaknemo malo, sicer pa močno
- Odločitev po primerjavi sivine in gradienta točke $\mathbf{z}_{l,i+1}$ in meritve z_{i+1}

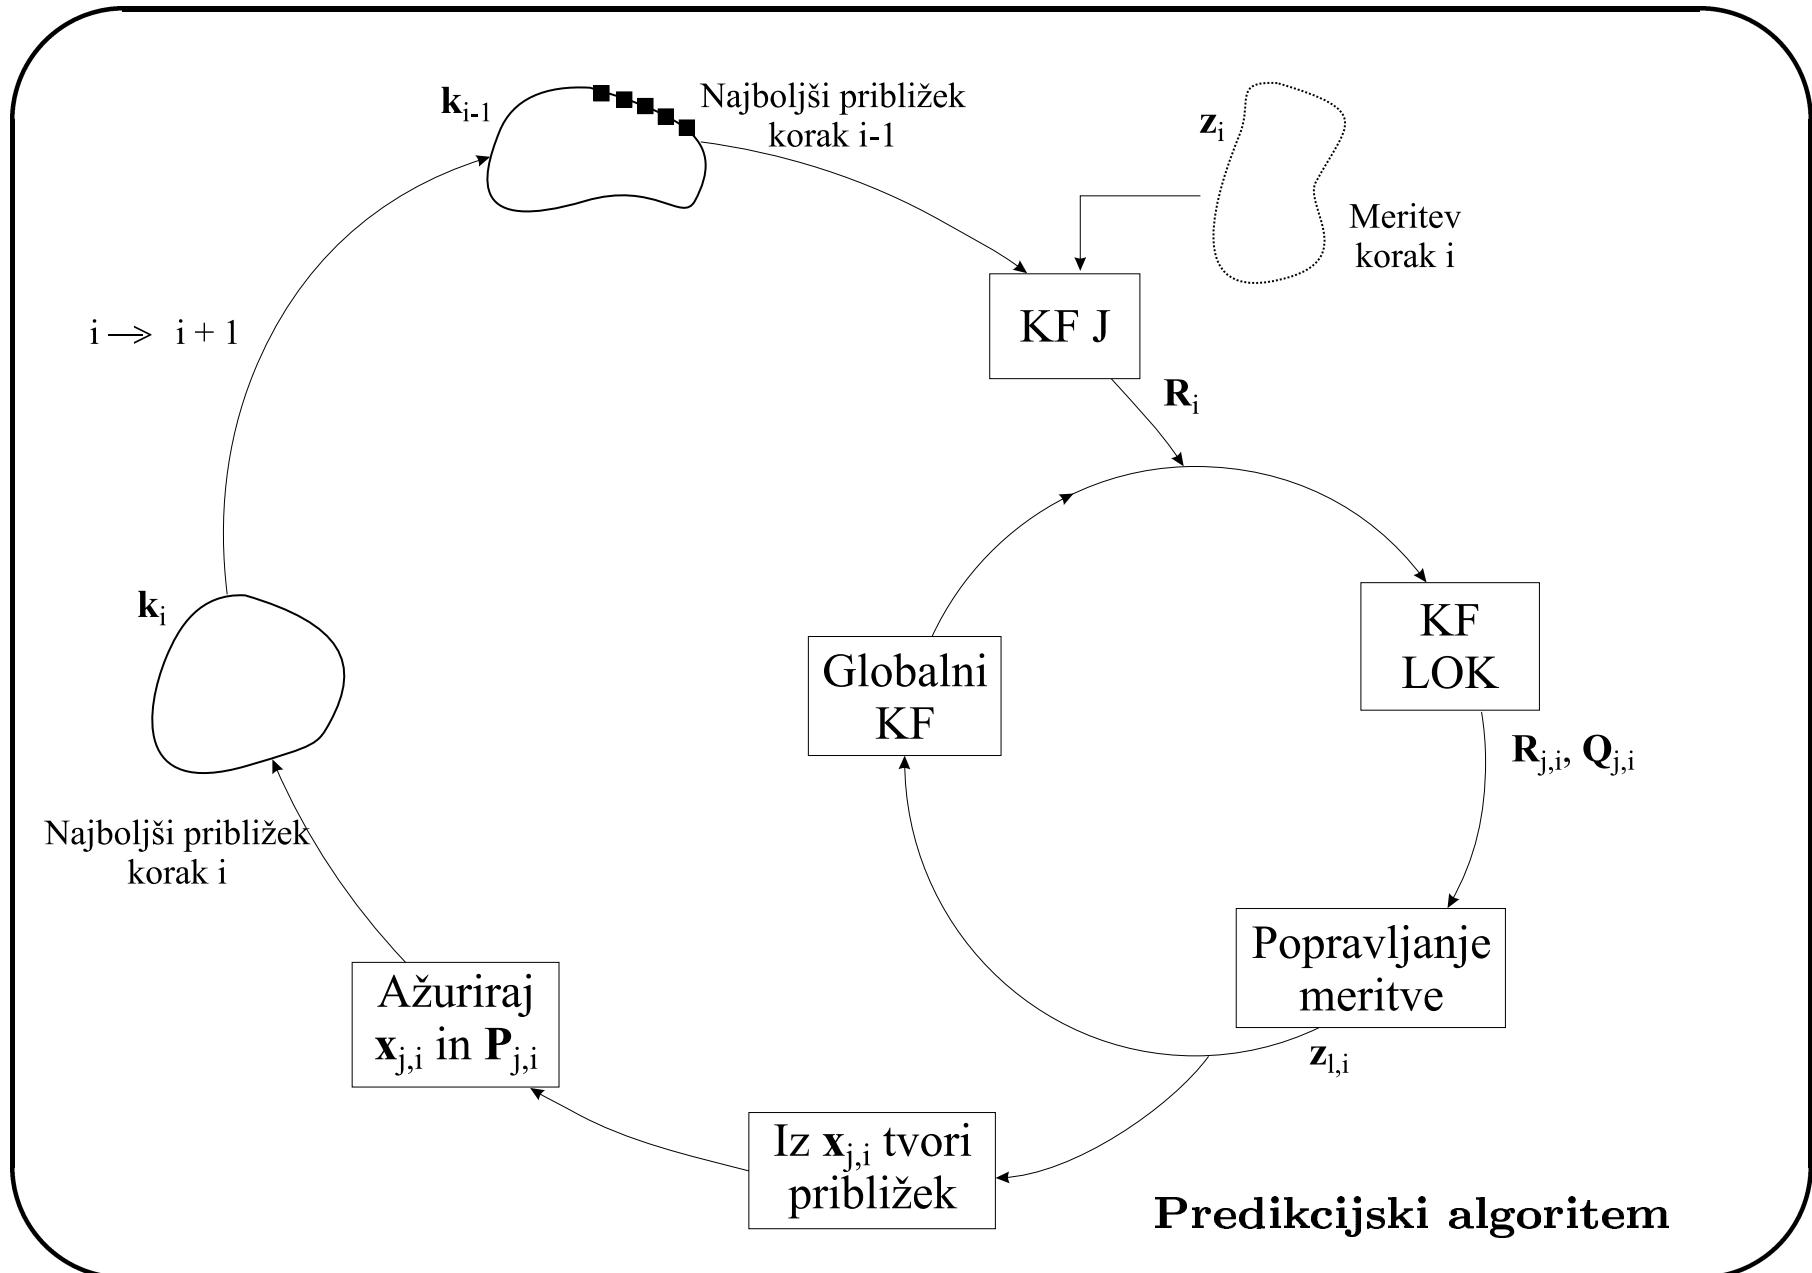
$$\mathbf{z}'_{l,i+1} = \mathbf{z}_{l,i+1} + \underbrace{\nu \cdot \frac{\overrightarrow{\mathbf{k}_{j,i} \mathbf{z}_{l,i+1}}}{\|\overrightarrow{\mathbf{k}_{j,i} \mathbf{z}_{l,i+1}}\|}}_{\Delta \mathbf{z}_{l,i+1}}$$

$$\nu = ct \cdot \|e(z_i, k_i)\|$$



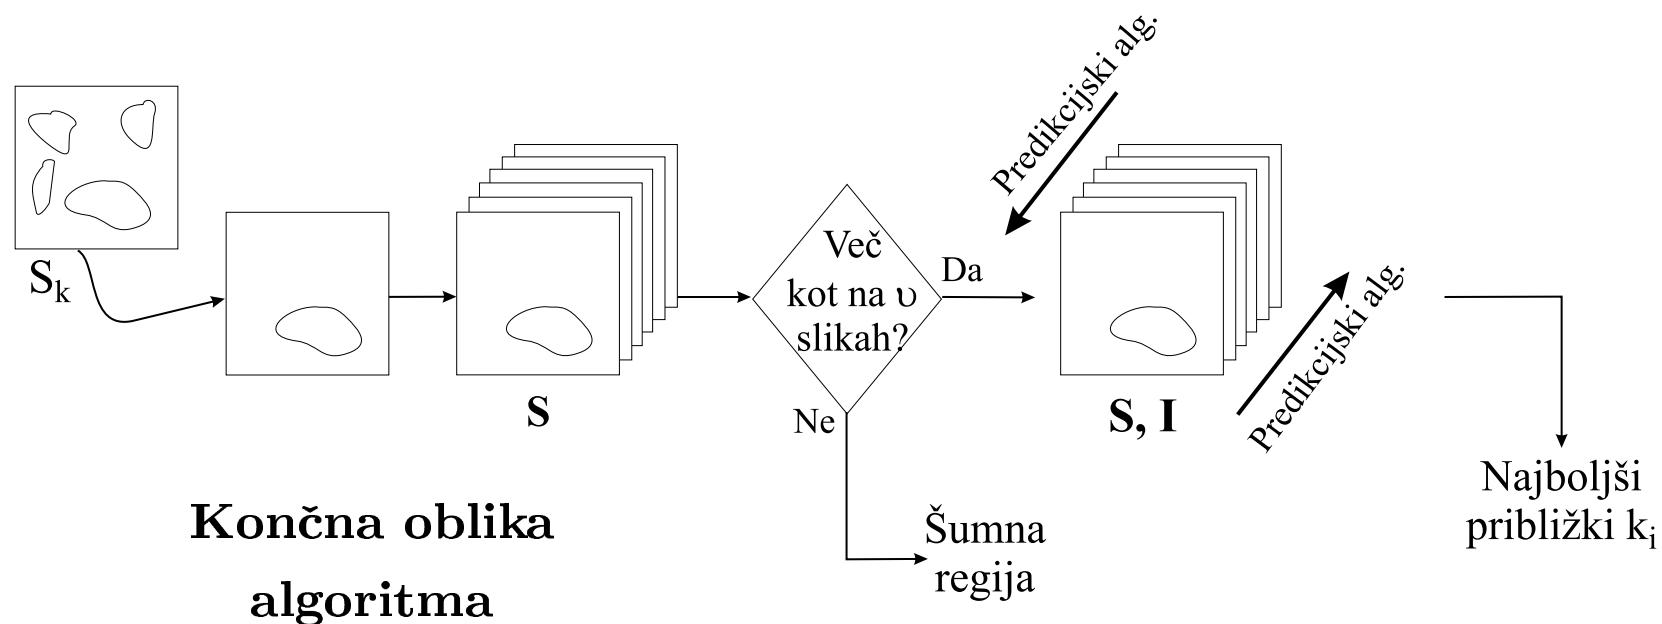
- Razdaljo vgradimo v Kalmanov filter J, popravek meritve $\Delta \mathbf{z}$ pa v globalni Kalmanov filter.

4. Razpoznavanje objektov s postopki predikcije



4.5 Končne izboljšave algoritma

- Prehodni pojav → zaporedje slik obdelamo v dveh prehodih (obe smeri)
- Več objektov v sliki → izločimo objekte, vsak objekt obdelamo s predikcijskim algoritmom
- Šumne regije → regija veljavna, če se pojavi vsaj na ϑ zaporednih slikah



5. Pregled rezultatov

Umetni ultrazvočni posnetki

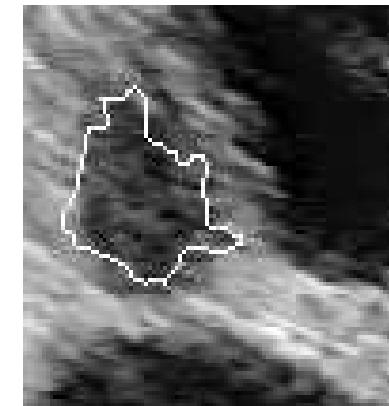
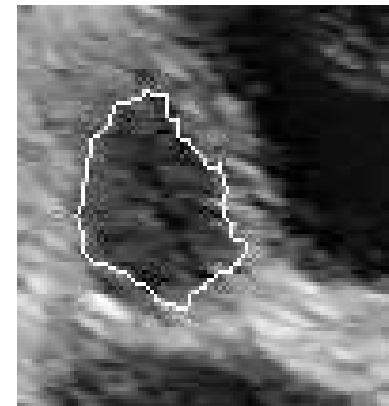
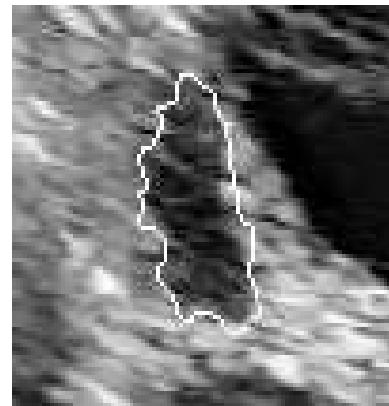
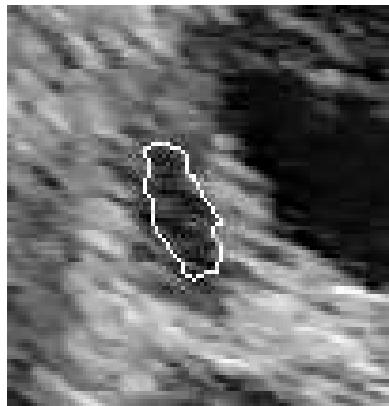
- 2 zaporedji (120 slik)
- znan točen položaj mešičkov
- statistično ovrednotenje rezultatov

Realni ultrazvočni posnetki

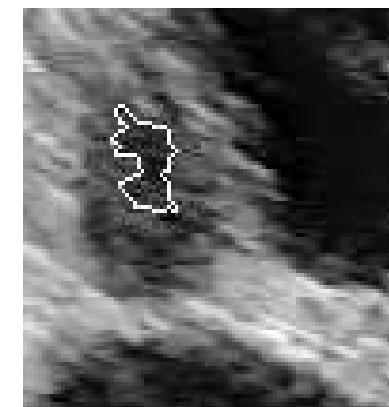
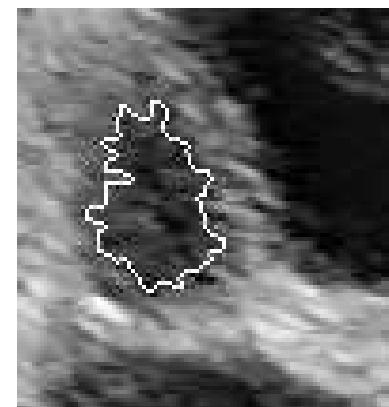
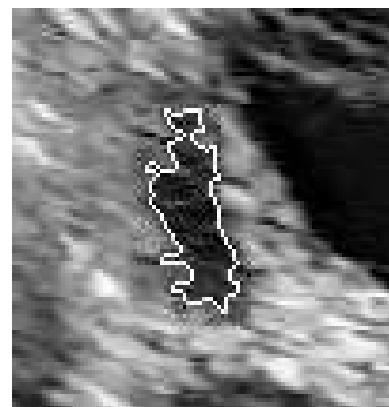
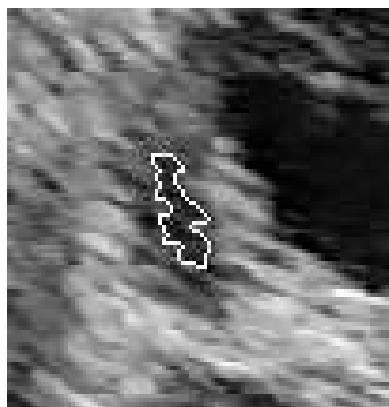
- 12 zaporedij (5000 slik)
- referenčni položaj mešičkov – ocene eksperta (približek)
- vizualno in primerjalno vrednotenje rezultatov

Vhod v predikcijski algoritmom: odčitki, dobljeni z algoritmom za razpoznavanje v statičnih 2D slikah

Obdelovanje regije skozi zaporedje slik



Predikcijski algoritem



1.

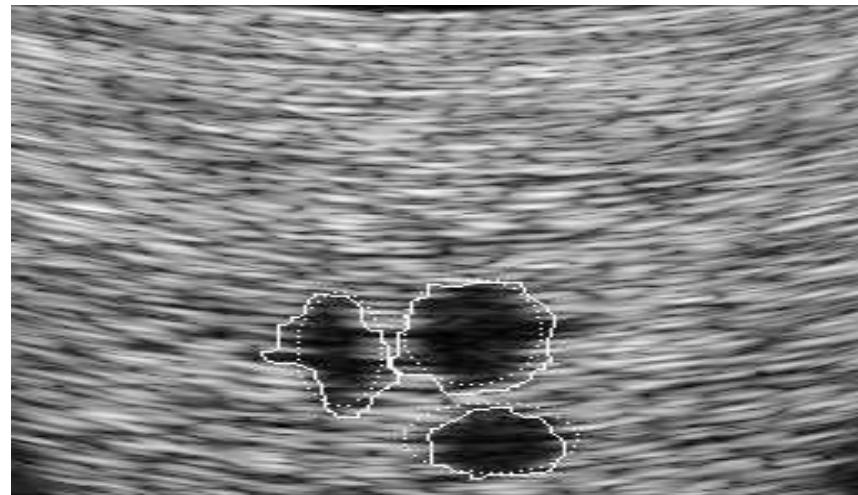
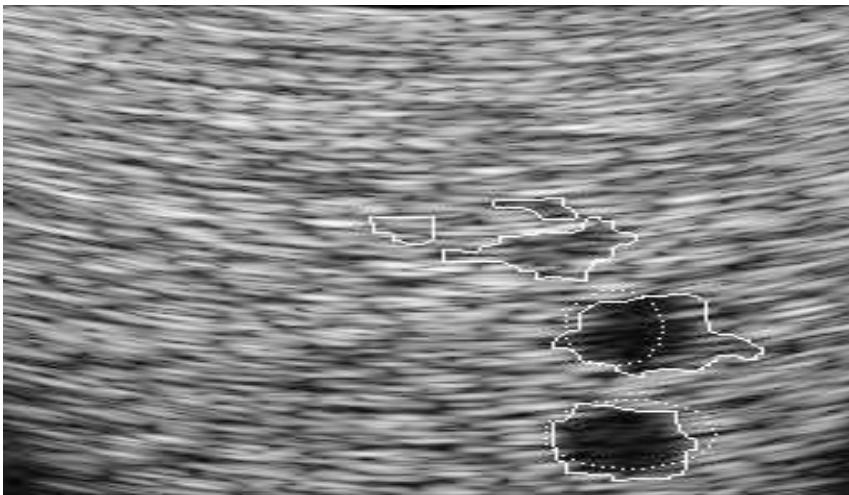
11.

29.

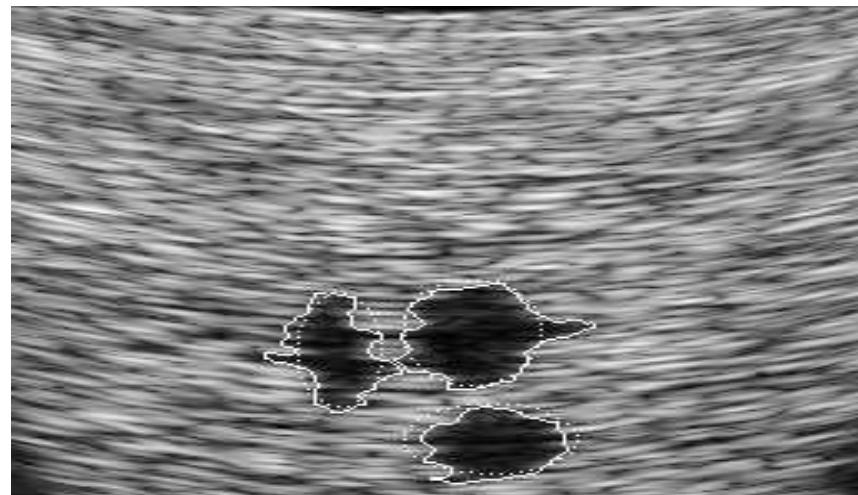
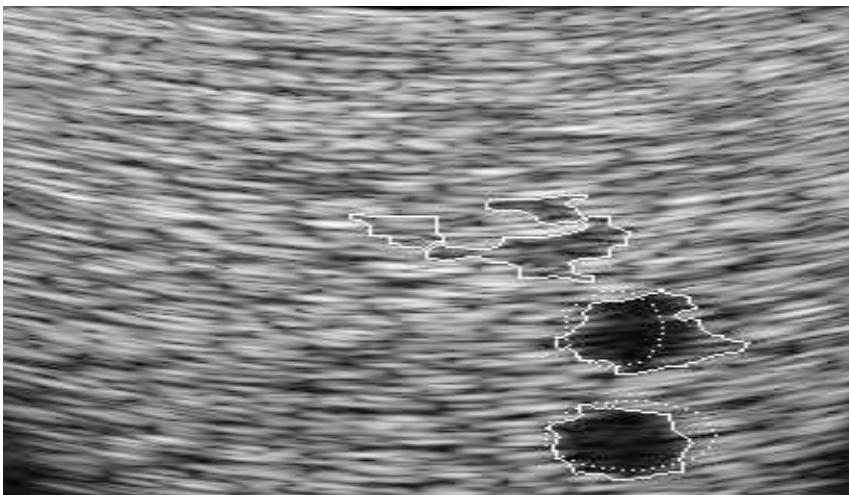
32.

Algoritem za statične 2D slike

Rezultati na umetnih slikah



Predikcijski algoritem



Algoritem za statične 2D slike

Rezultati na realnih slikah



Predikcijski algoritem

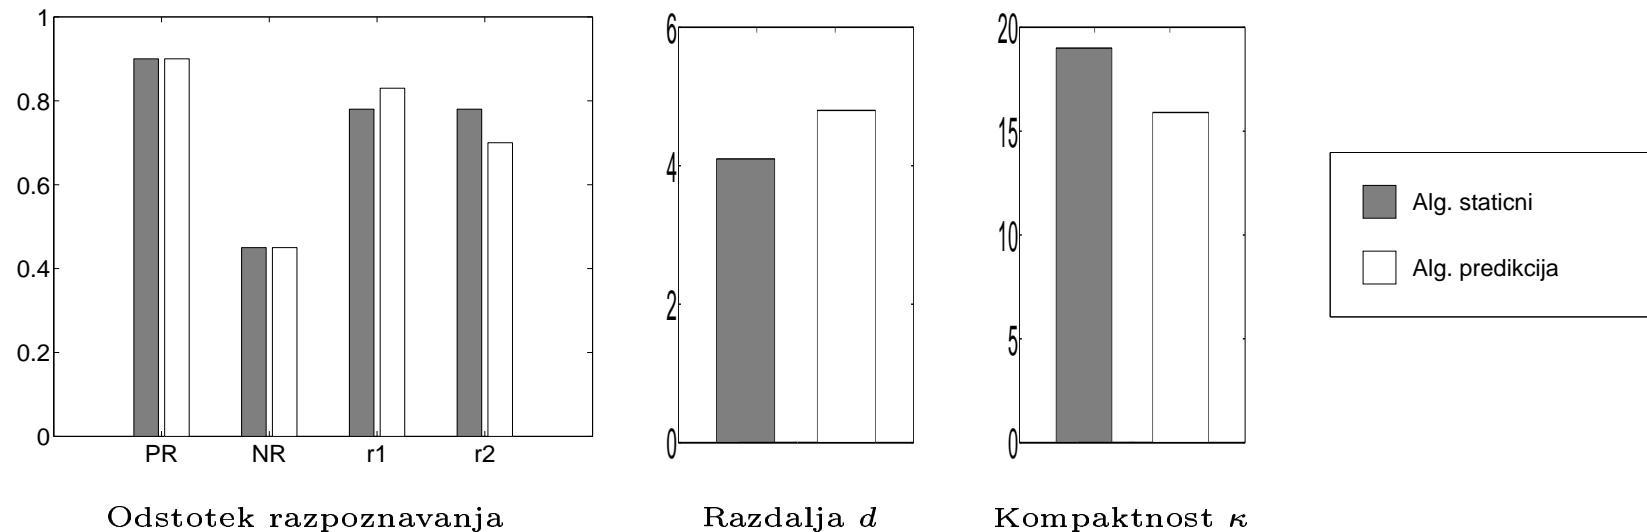


Algoritem za 2D slike

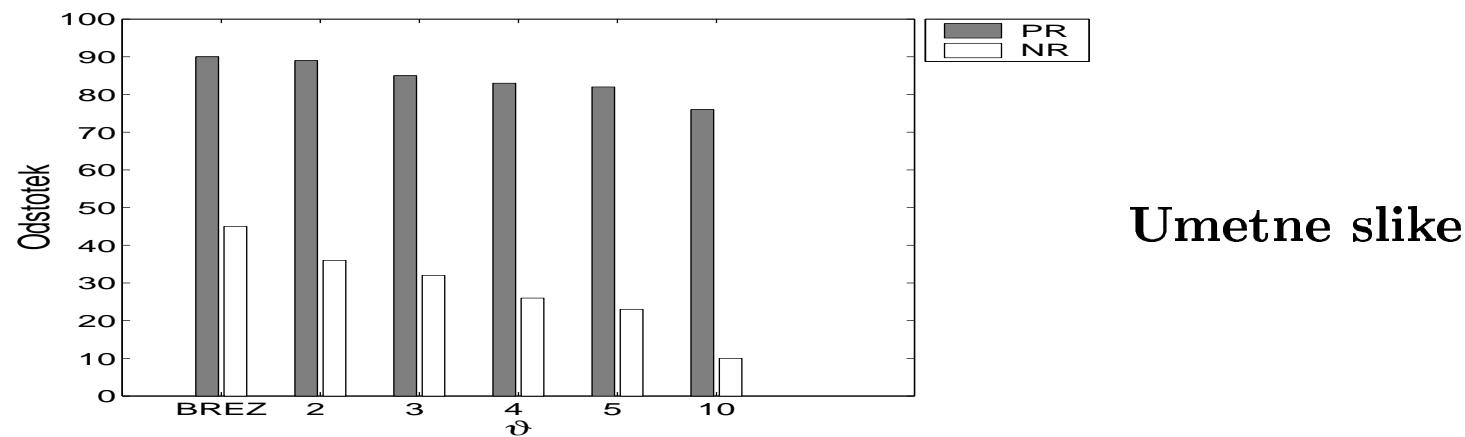


Ekspertove označbe

a) Parameter ϑ ni upoštevan



b) Parameter ϑ upoštevan



Večja gotovost v pravilnost dobavljenih rezultatov



-3



-1



0



+5



Predikcijski algoritem



Ekspertove označbe

Prednosti:

- + Objekti razpoznani z večjo natančnostjo
- + Razpoznavi objekti kompaktnejši
- + Odstotek napačno razpoznavanih objektov se zmanjša
- + Večja gotovost v pravilnost dobljenih rezultatov

Slabosti:

- Velika časovna in prostorska kompleksnost

6. Sklep

- V disertaciji smo se ukvarjali z avtomatskim razpoznavanjem objektov iz zaporedja 2D posnetkov.
- Podroben pregled obstoječih metod razpoznavanja iz zaporedja.
- Nova algoritma za avtomatsko razpoznavanje objektov iz zaporedja 2D slik:
 - algoritem za razpoznavanje v statičnih 2D slikah
 - algoritem za razpoznavanje iz zaporedja slik s postopki predikcije
- Simulator za tvorjenje ultrazvočnih posnetkov jajčnikov:
 - vpeljali 3D model jajčnika z mešički
 - prvi simulator s tega področja

- Algoritem za statične 2D slike:
 - edinstvena izvedba rasti regij (statistični testi, obtežen gradient)
 - avtomatsko razpoznavanje
 - eden najboljših algoritmov za razpoznavanje mešičkov
- Predikcijski algoritem:
 - Kalmanov filter uporabljen prvič na tak način (sledenje krivulji)
 - 3 izboljšave osnovne oblike algoritma
 - večja kvaliteta, zmanjšanje števila napačno razpoznanih mešičkov
 - prvi algoritem za razpoznavanje jajčnih mešičkov iz zaporedja

⇒ Na osnovi dobljenih rezultatov trdimo, da je teza dokazana.