

UPORABA LOKALNE OPISNE STATISTIKE
PRI SEGMENTACIJI
MAGNETNO REZONANČNIH SLIK MOŽGANOV

Andrej Vovk

SEGMENTACIJA – razdelitev na smiselna področja

Lociranje objektov (satelitske slike; ceste, gozdovi...)

Prepoznavna obraza, prstnih odtisov,


Kontrola prometa

Prepoznavna zavornih luči

Strojni vid

V agrokulturi – prepoznavna boleznih pridelka,

V medicini...



SEGMENTACIJA – razdelitev na smiselna področja

Lociranje objektov (satelitske slike; ceste, gozdovi...)

Prepoznavna obraza, prstnih odtisov

Kontrola prometa

Prepoznavna zavornih luči

Strojni vid

V agrokulturi – prepoznavna boleznih pridelka,

V medicini...



SEGMENTACIJA – razdelitev na smiselna področja

Lociranje objektov (satelitske slike; ceste, gozdovi...)

Prepoznavna obraza, prstnih odtisov

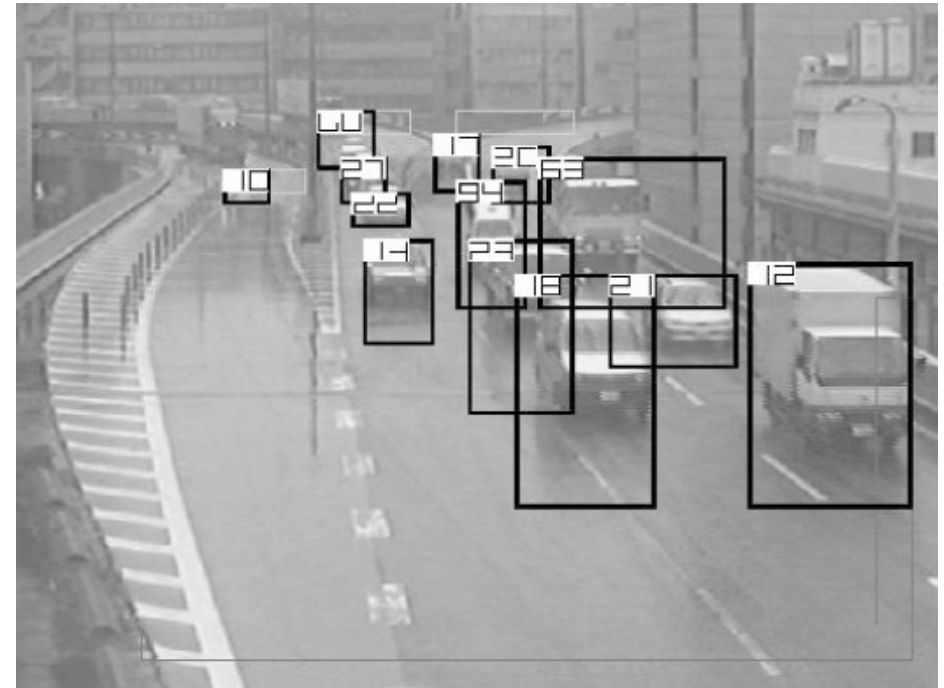
Kontrola prometa

Prepoznavna zavornih luči

Strojni vid

V agrokulturi – prepoznavna boleznih pridelka,

V medicini...



SEGMENTACIJA – razdelitev na smiselna področja

Lociranje objektov (satelitske slike; ceste, gozdovi...)

Prepoznavanje obraza, prstnih odtisov

Kontrola prometa

Prepoznavanje zavornih luči

Strojni vid

V agrokulturi – prepoznavanje bolezni pridelka


V medicini...



V medicini

Uporaba anatomske informacije za:

- kvantitativno klinične študije patoloških sprememb,
- diagnostika,
- lokalizacija patoloških sprememb,
- študija anatomskih struktur in analiza možganske skorje,
- pri izdelavi anatomskih atlasov,
- načrtovanju zdravljenja,
- pri računalniško podprtih operacijah,...



CSF, GM in WM

Problemi:


- senčenje
- šum
- strukturne nepravilnosti objekta
- starostne razlike

Segmentacijski algoritmi:*

metode pragov, metode rasti območij, metode uvrščanj (klasifikacije), metode razvrščanj, model Markovskih naključnih polj, nevronske mreže, deformacijske modele in metode, ki uporabljajo prostorske atlase.

- **anatomske atlase**; ti zagotavljajo apriori informacije o prostorski razporeditvi vrst tkiv. (pokaži v AFNI)
- Možgane, ki jih želimo segmentirati, moramo poravnati na povprečne možgane.
To je proces, ki je tudi občutljiv na šum ter senčenje

- FLIRT – (FMRIB'S Linear Image Registration Tool)



- NAMEN: razviti avtomatski postopek za generiranje verjetnostnih map,
- odporen na šum in senčenje,
 - ni registracije/poravnave na normalne anatomske predloge

$$\vec{s}_i = [stat_1(Y_{i1}), stat_1(Y_{i2}), \dots, stat_1(Y), stat_2(Y_{i1}), \dots, stat_2(Y), \dots, stat_m(Y)]$$


i - indeks voksla

\vec{s}_i - podpis = vektor m opisnih statistik v n prostorskih sosednostih

y_i - intenzivnost sivine voksla

Y_{ij} - nabor intenzivnosti sivin vokslorv znotraj krogle s premerom j mm s središčem v vokslu i ;

$stat_k(Y)$ - opisna statistika, izračunana na naboru Y .



TREND PODPISOV PROSTORSKI OBSEG

bistvena informacija

Podpisi (vektorji povprečij) v različnih tkivih

vokslu podobnih vrst tkiv in lokalne strukture – podobni podpisi

$y_{i,z} = g_z(f_{i,z} v_i) + h_z + \epsilon$ Osnovni zapis intenzivnosti MR v vokslu i , med slikanjem z

v_i - želena intenzivnost voksla

g, h - specifična parametra snemanja

$f_{i,z}$ - senčenje

ϵ - šum

PREDPOSTAVIMO

l_r dovolj majhen $\rightarrow f_{i,z} = \text{konst.}$

$y_{i,z,l_r} \approx g_z f_{i,z} v_{i,l_r} + h_z$ - mediana

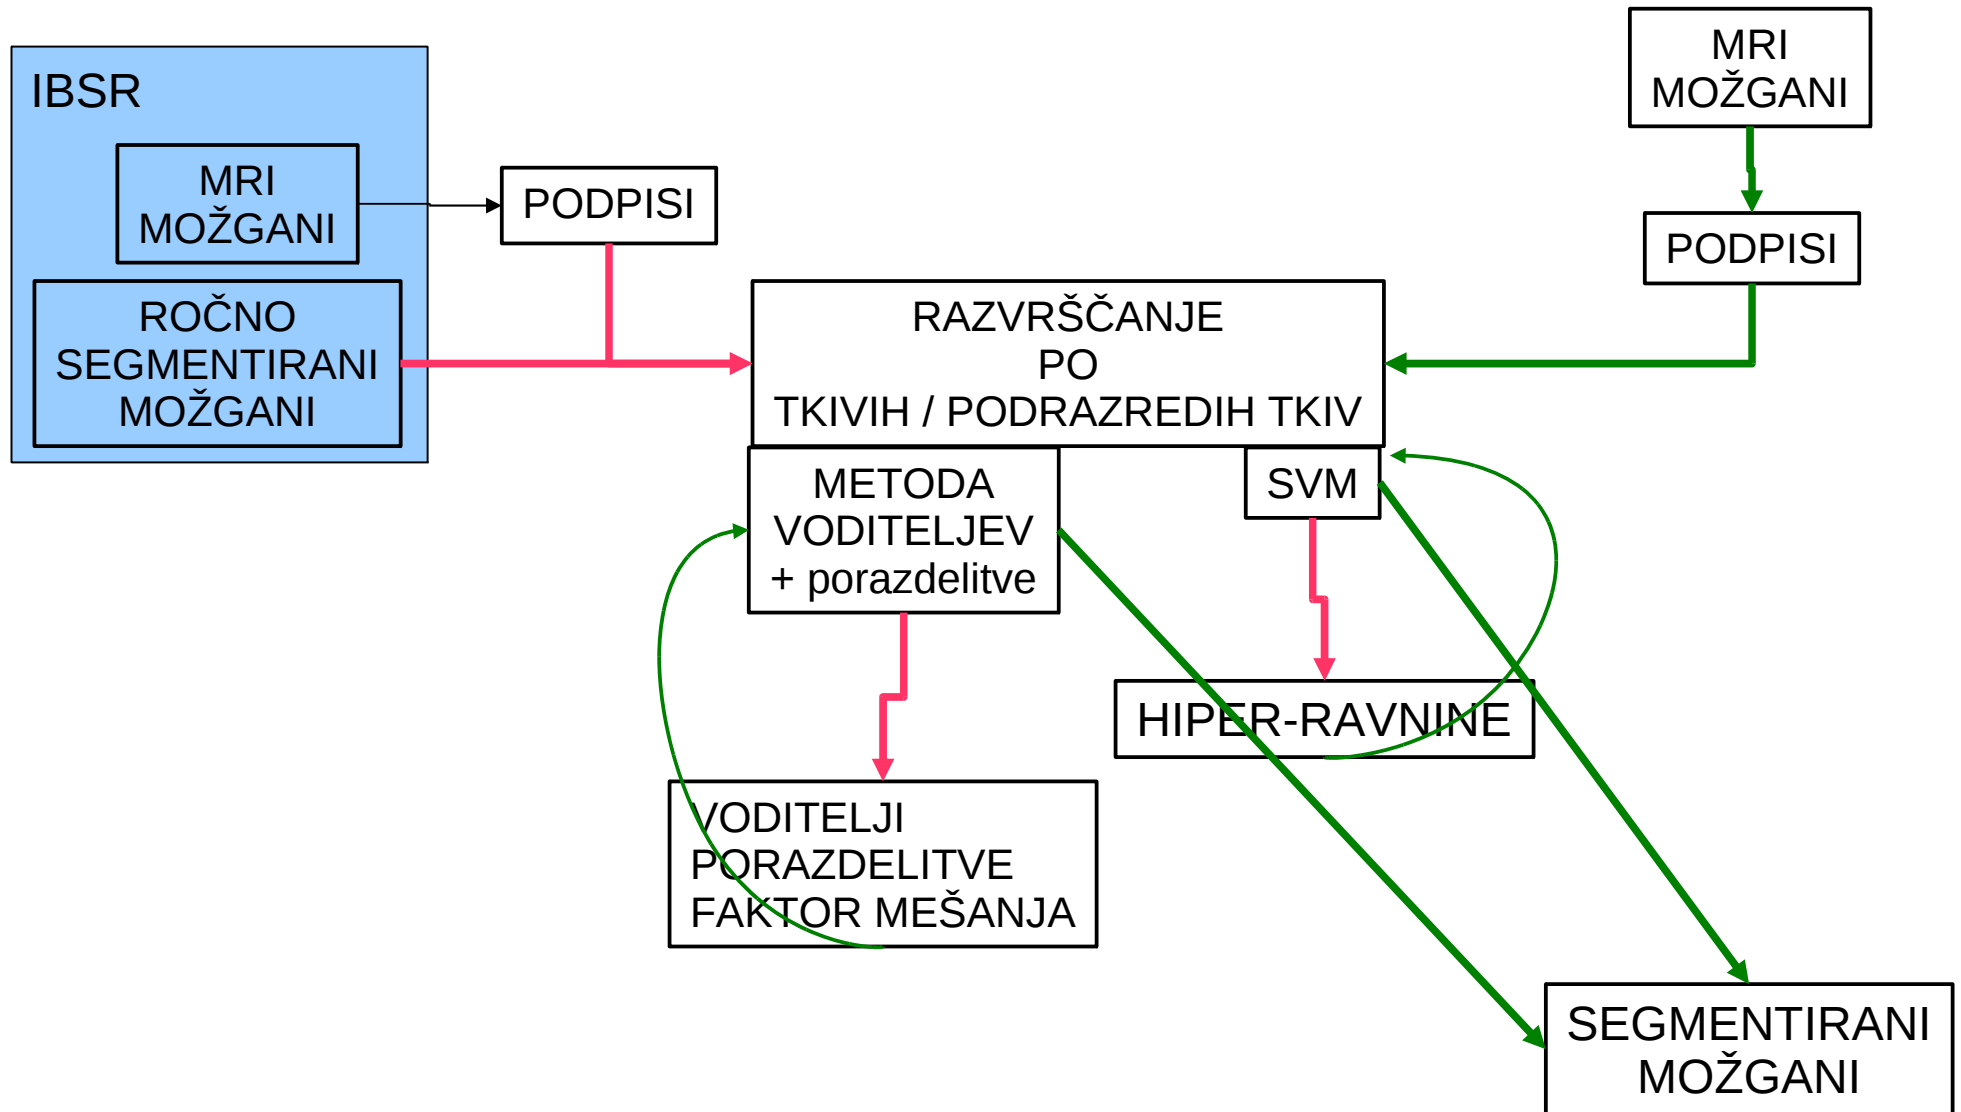
$MAD_{i,z,l_r} \approx g_z f_{i,z} MAD_{i,l_r}$ - medianin absolutni odklon

$G = 3 \frac{(\bar{y} - y)}{s} \rightarrow G_{i,z,l_r} \approx \frac{3g_z f_{i,z} (y_{i,l_r} - \bar{y}_{i,l_r})}{g_z f_{i,z} s_{i,l_r}} \approx \frac{3(y_{i,l_r} - \bar{y}_{i,l_r})}{s_{i,l_r}}$ - skew (Pearsonov drugi koeficient asimetrije)

$\vec{s}_{\tilde{y}(i,z,l_r)} \approx g_z f_{i,z} \vec{s}_{\tilde{v}(i,l_r)} + h_z$ Odstranimo povprečje $\vec{s}_{y(i,z,l_r)} \approx g_z f_{i,z} k_1 + g_z f_{i,z} \vec{d}_{i,l_r} + h_z \approx g_z f_{i,z} \vec{d}_{i,l_r} + k_2 \rightarrow \vec{s}_{y_0} \approx g_z f_{i,z} \vec{d}_{i,l_r}$

$\vec{s}_{MAD_y(i,z,l_r)} \approx g_z f_{i,z} \vec{s}_{MAD_v(i,l_r)}$ Standardiziramo z MAD pri l_{rmax} $\frac{\vec{s}_{MAD_{y_0}}}{k_3} \approx \frac{\vec{s}_{MAD_v}}{MAD_v(i, l_{rmax})}$

$\vec{s}_{G_y(i,z,l_r)} = \vec{s}_{G_v(i,l_r)}$



Metoda voditeljev

NENADZOROVANA
PREPROSTA
HITRA

obdelovanje obsežnih podatkovnih baz

- Uporaba različnih podobnosti.

- Zaradi možnih vezanih dogodkov se uporablja Pearsonova korelacija med vektorji rangov. *

$$\rho = \frac{1}{n} \sum_{i=1}^n \frac{(x_i - \bar{x})}{\sigma_x} \frac{(y_i - \bar{y})}{\sigma_y}$$

- Mera različnosti je v knjižnici razvrščanja, ki sem jo uporabil, izražena kot:

$$d = 1 - \rho$$

Pri iskanju novega voditelja iščemo minimum kriterijske funkcije, ki je podana kot:

$$P(C) = \sum p(C)$$



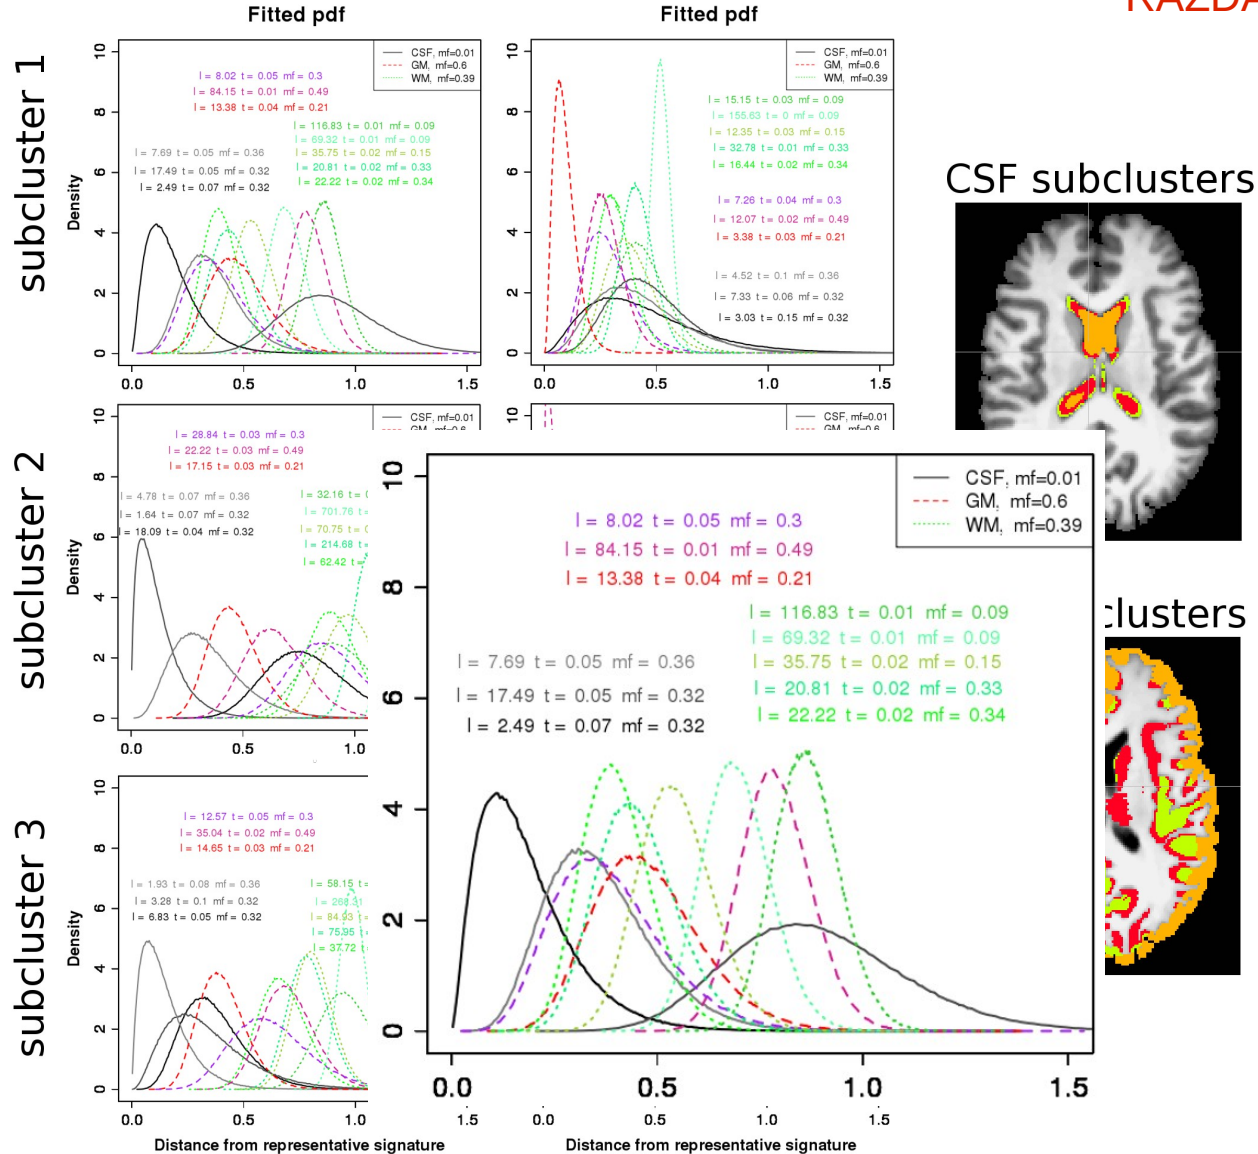
- napaka skupine (lokalna)

Metoda voditeljev - učenje

CSF

GM

MODELIRANJE PORAZDELITEV RAZDALJ/RAZLIČNOSTI



od podpisov podrazredov do posameznih
reprezentativnih podpisov = voditeljev podrazredov

Metoda voditeljev – računanje verjetnosti

ocena verjetnosti pripadnosti voksla določenemu tkivu
glede na oddaljenost od reprezentativnih podpisov

Končna verjetnost pripadnosti voksla v podrazred r

$$P(c_i=r) = \prod P(c_i=r | \delta_{i,r}, T_r)$$

produkt vseh verjetnosti istega podrazreda r
pridobljenih z različnimi reprezentativnimi voditelji

$$P(c_i=r | \delta_{i,r}, T_1, \dots, T_L) = \frac{P(c_i=r) * P(\delta_{i,r} | c_i=r, T_r)}{\sum P(c_i=r) * P(\delta_{i,r} | c_i=r, T_r)}$$

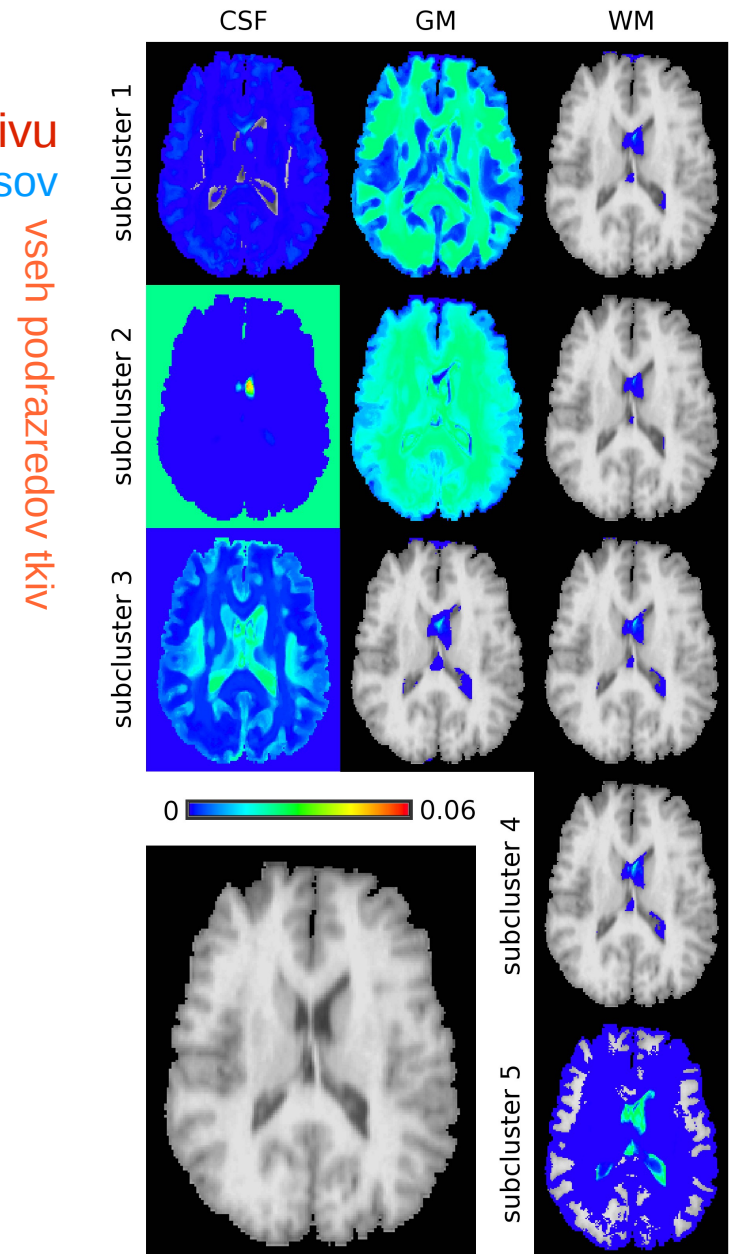
kjer je

c_i - razred voksla i

$p(c_i=k)$ - parameter mešanja;

$p(\delta_{i,r} | c_i=k)$ - verjetnost razdalje $\delta_{i,r}$ v danem razredu k ;


$p(c_i=r | \delta_{i,1..R})$ - verjetnost razreda pri danih razdaljah



SVM

Algoritem SVM išče ravnine, ki ločijo pozitivne in negativne elemente.

- hiperravnino z največjo širino robov
- določitev zgornje meje števila napak pri učenju
- preoblikovanje podatkov v višje dimenzije
-> poenostavi izračun hiperravnin



- **učenje** na treh od 18 IBSR volumnov
- v vsakem podrazredu omejil na 100 podpisov
- knjižnica libSVM v programskem paketu R

Podrazredi

- za zmanjšanje heterogenosti podpisov v posameznem tkivu
- vsako tkivo v 3 podrazrede;
 1. podrazred sestavljajo vokseli 1. in 2. plasti (približno 2-3mm globoko),
 2. podrazred vsebuje 3. in 4. plast,
 3. podrazred vsebuje vse globlje plasti (> 4-6mm globoko).

Senčenje


Testiranje robustnosti - dodajanje neenakomerne intenzivnosti s polinomom 3. reda
(BrainWeb Simulated Brain Database)

Ocenjevanje / primerjava atlasov verjetnosti

- klasifikacija na podlagi maksimalne verjetnosti tkiv WM, GM in likvorja v posameznem vokslu in primerjava tovrstne klasifikacije med prostorskimi atlasii in verjetnostnimi atlasii podpisov (registracija FLIRT in FNIRT iz paketa FSL)
- uporaba verjetnostnih atlasov podpisov v segmentacijskem programu FAST
- za ocenitev rezultatov klasifikacije B z rezultati ročne segmentacije A
Diceov koeficient:

$$DSC(A,B) = 2 \frac{(A \cap B)}{(A) + (B)}$$

Prepoznava tumorskega tkiva z uporabo podobnosti podpisov.



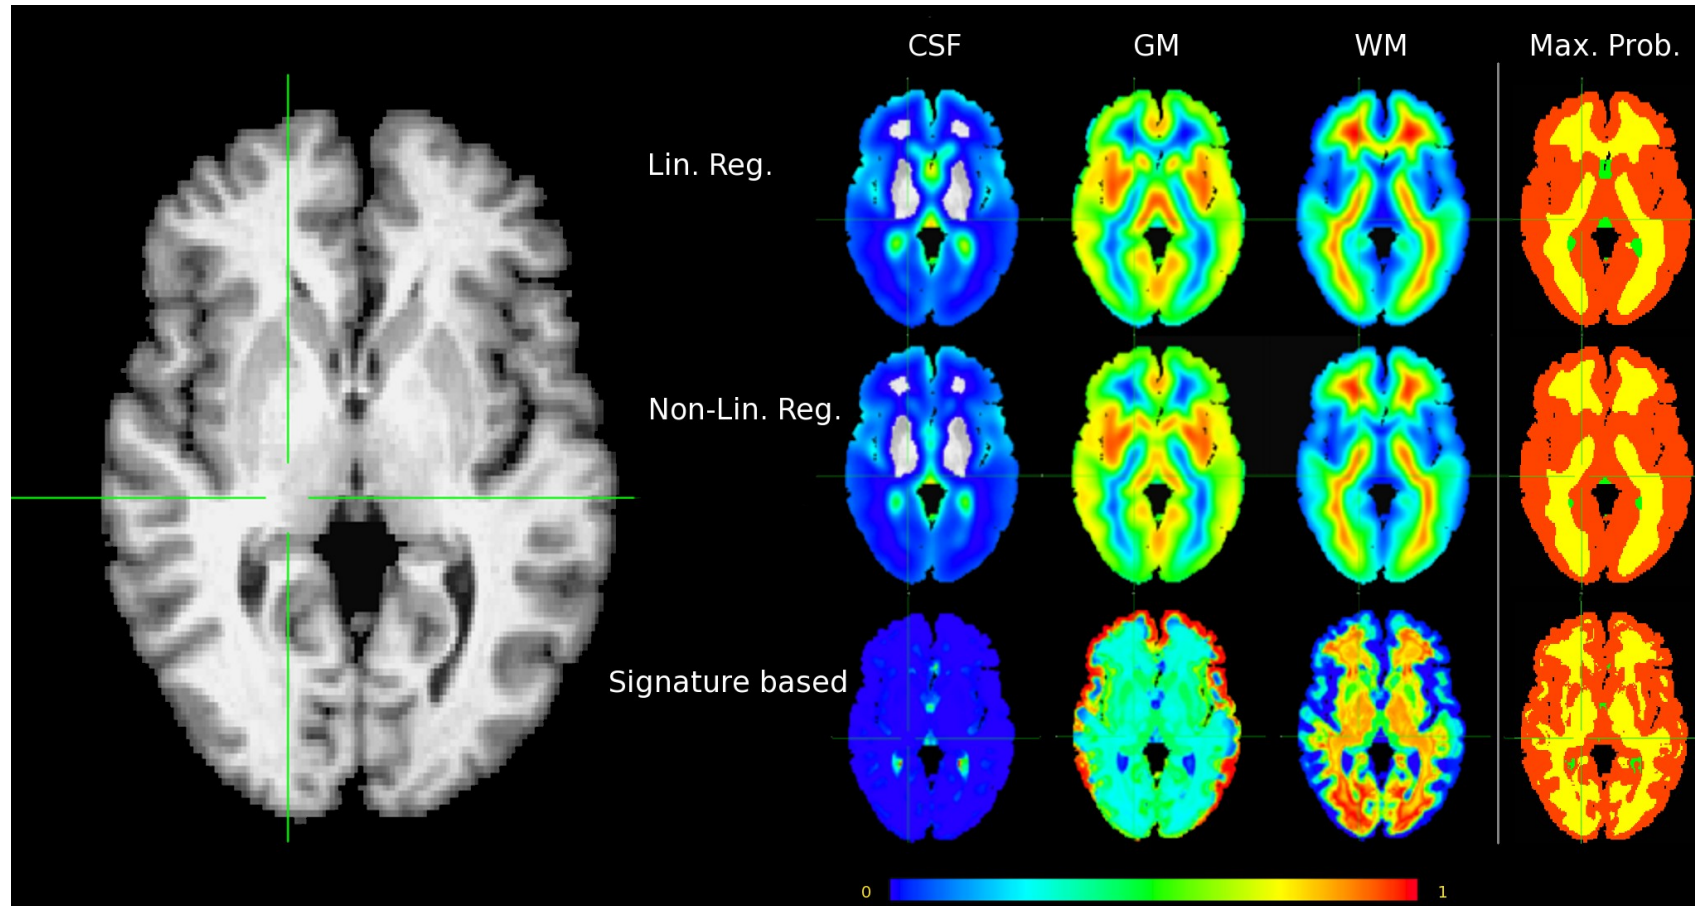
(A) referenčni podpis je izbran v sredini prikazanega križca.

Barvna mapa prikazuje podobnost podpisov.

Opazimo lahko, kako velika večina najbolj podobnih podpisov pripada cisti.

(B) tkivo tumorja, ki je po intenzivnosti sivine podoben signalu beline, je ostro obrobljeno. V tem primeru sem izbral 3 referenčne podpise in nato izračunal povprečje treh dobljenih mask.


Atlasi verjetnosti



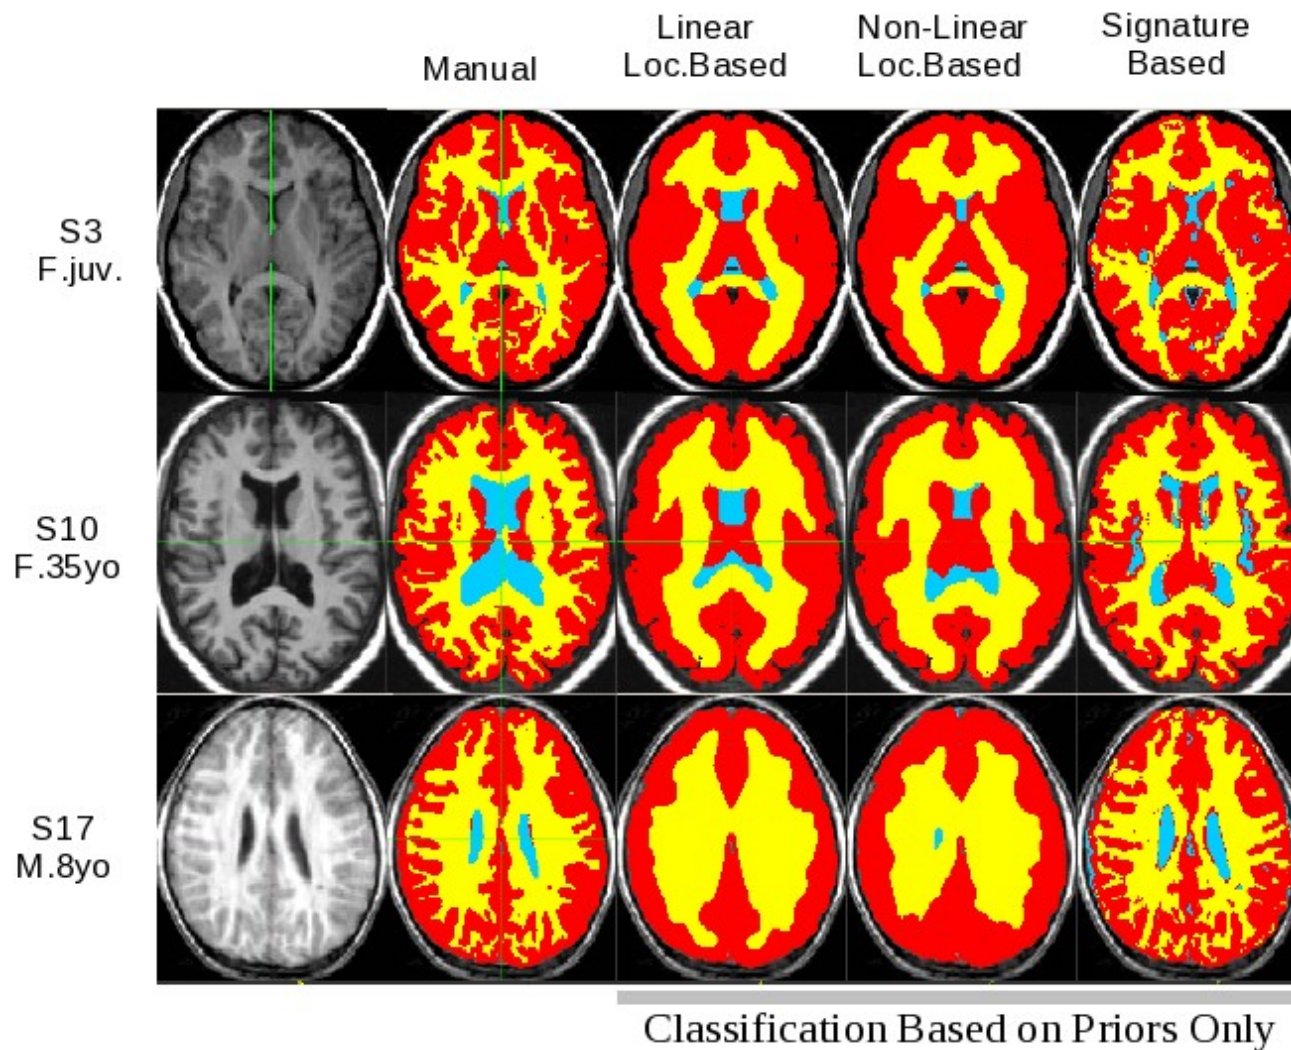
Klasifikacija izračunana z največjo verjetnostjo.

SVM

Tissue Probability Maps




*Histogrami p za voksle
 v celotni maski možganov (črna pikčasta črta)
 in tiste v tkivu določene maske (rdeča polna črta).*




*Klasifikacija na osnovi podpisov bolje sledi
orisu anatomije posameznika v vseh treh primerih.*

Original IBSR Volumes




Bias Field Added




Rdeče črte
- klasifikacij z atlasih podpisov,

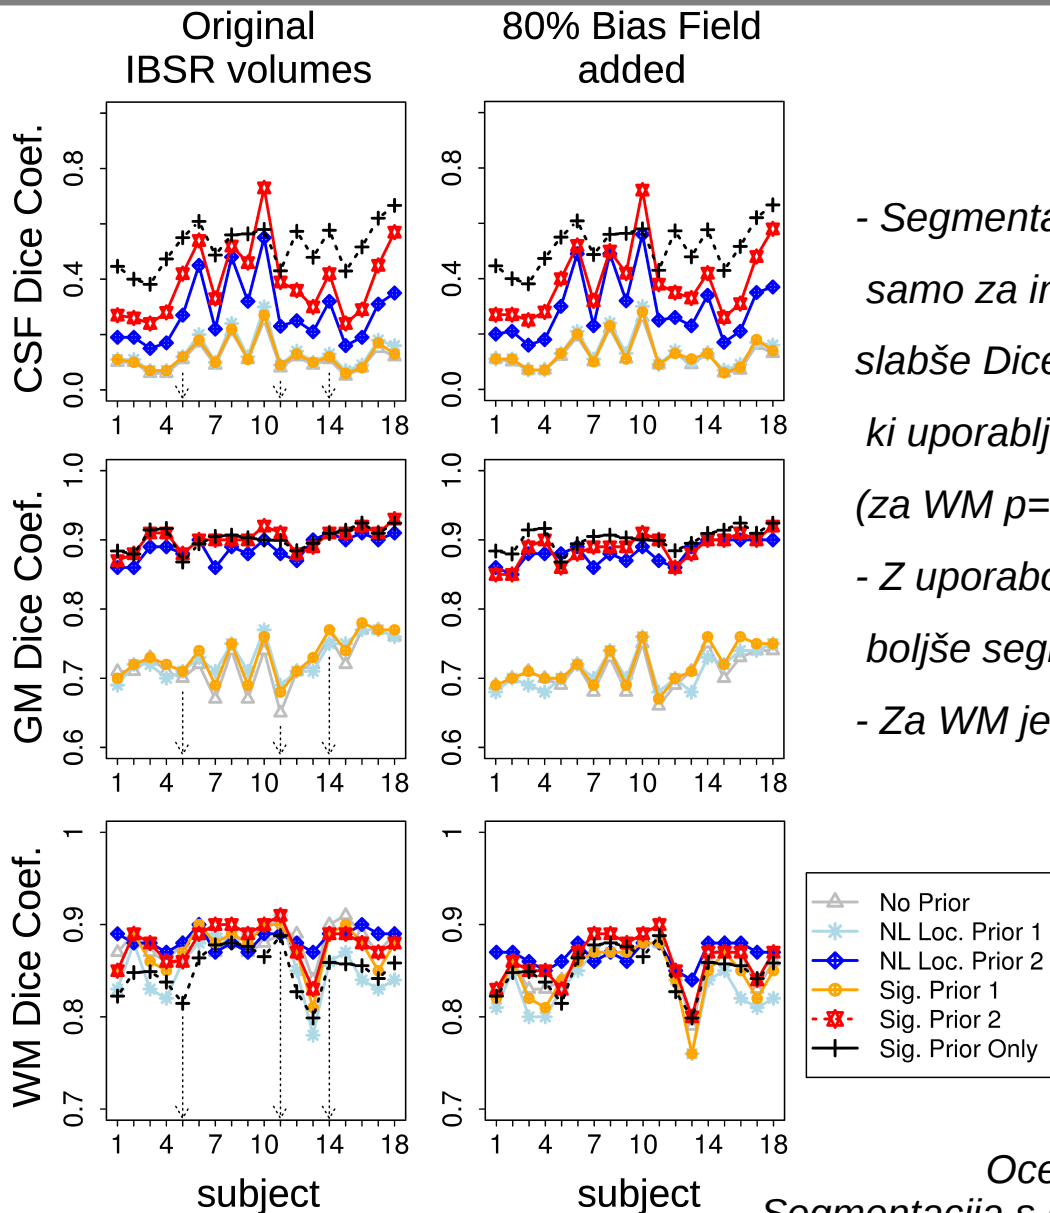
Modre in zelene črte
- klasifikacije z
linearno in nelinearno
registriranimi prostorskimi atlasih

Original Volume



80% Bias Field Added





- Segmentacija brez ali z uporabo priorjev samo za inicializacijo segmentacije daje signif. ($p < 0,01$) slabše Diceove koeficiente, v primerjavi s segmentacijo, ki uporablja priorje v celotnem postopku segmentacije. (za WM $p = 0,08$).
- Z uporabo priorjev podpisov dobimo signif. ($p < 0,01$) boljše segmentacije za GM in CSF.
- Za WM je izboljšanje statistično manj signif. ($p < 0,05$).

Ocena končne segmentacije z različnimi priorji.
Segmentacija s prog. FAST v CSF, GM in WM na 5 načinov.

Črna črta za primerjavo predstavlja Diceove koeficiente za enostavno klasifikacijo samo s priorji podpisov.

Izbira tekstur

- rotacijsko neodvisni, neobčutljive na senčenje in razpon intenzitet sivin
- dodatne teksture -> večje natančnosti in razmejevanje tkiv na več razredov

Izbira razredov in podrazredov

- večina napak izhaja iz 1. plasti - na stičišču tkiv različnih vrst
- možna razširitev na več razredov

Izbira razpona prostorskih sosednosti

- majhnih sosednostih - prostorske podrobnosti
- dovolj velik prostor, da zajame teksturo, kjer se sivina, belina in likvor razlikujejo

Metoda voditeljev

- omogoča uporabo različnih razdalj/podobnosti za mero različnosti
- pomanjkanje jamstva konvergence v globalni optimum (hierarhično razvrščanje)

SVM

- neuravnoteženost podatkov (likvor)

Nov pristop na podlagi podpisov proizvede priorje tkiv
-> za inicializacijo in vodenje segmentacije možganov.

Za povezavo podpisov z vrstami tkiv sem uporabil metodo voditeljev in klasifikacijsko metodo SVM.

Optimizacija potrebna samo v fazi učenja za izračun voditeljev
ali SVM hiperravnin in s tem povezanimi porazdelitvami; proces, ločen od segmentacije.

Priorji dobljeni s podpisi, dajo statistično značilno boljše rezultate klasifikacij ter segmentacij
v primerjavi z uporabo lokacijskih priorjev.

Pristop loči vrste možganskih tkiv in je uporaben za kvantitativno odmero možganske poškodbe:
-> **sklep**, da so izračunani reprezentativni podpisi v pomoč pri objektivnih diagnostičnih postopkih.