



Aalto-yliopisto  
Perustieteiden  
korkeakoulu


# Aivojen magneettikuvien automaattinen segmentointi

# Sisältö

- Yleistä:
  - Mitä tarkoitetaan segmentoinnilla?
  - Miksi segmentoidaan?
- Miten segmentoidaan?
  - Priori: ennakkotiedot
  - Segmentoinnissa käytettävät mallit
  - Parametrien optimointi

# Mitä tarkoitetaan segmentoinnilla?

- Jakamista alueisiin
- Aivokuvien tapauksessa halutaan löytää aivojen funktionaaliset rakenteet (yli 700)
- Keskitytään tärkeimpiin, joita on noin 50




# Miksi segmentoidaan?

- Päästään käsiksi tärkeään informaatioon
  - Aivoalueiden koko
  - Kasvaimet
- Lääkkeiden kehitys
  - Kvantitatiivista informaatiota
- Manuaalinen segmentointi
  - Hidasta
  - Tulokset vaihtelevat segmentoijasta riippuen

# Mitä segmentoidaan?

- Aivokuvat sisältävät intensiteettidataa
- Eri anatomisilla rakenteilla eri intensiteetti
- Eri funktionaaliset alueet voivat koostua samoista anatomisista rakenteista




# Miten segmentoidaan?

- Tarvitaan tietoa siitä, missä rakenteet suunnilleen ovat
  - Piori
- Helppoin segmentointi:
  - Segmentoi yksi kuva manuaalisesti, ja aseta uuden kuvan päälle
- Yleisemmin:
  - Piori useammasta kuvasta
  - Rakennetaan malli ja sämplätään siitä
  - Saadaan kartta aivorakenteista

# Miten segmentoidaan?


- Muodostetaan statistinen malli magneettikuvan muodostumisesta




- Malli riippuu (joistain) parametreista:  $\boldsymbol{\theta} = (\boldsymbol{\theta}_l^T, \boldsymbol{\theta}_d^T)^T$

# Käänteisongelma

- Malli magneettikuvan muodostumiselle, mutta miten päästään intensiteettikuvasta valmiseen segmentointiin



MRI image  $\mathbf{d}$



Label image  $\mathbf{l}$

- Pelataan Bayesin kaavoilla:  $\hat{\mathbf{l}} = \arg \max_{\mathbf{l}} p(\mathbf{l}|\mathbf{d}, \theta)$

# Malleista



$p(\mathbf{l}|\boldsymbol{\theta}_l)$


Label image  $\mathbf{l}$

- Määrätään jokaiselle vokselille rakenne
- Todennäköisyys rakenteelle  $k$  on  $\pi_k$

$$p(\mathbf{l}|\boldsymbol{\theta}_l) = \prod_n \pi_{l_n}$$

$$\boldsymbol{\theta}_l = (\pi_1, \dots, \pi_K)^T$$

# Malleista



$p(\mathbf{d}|\mathbf{l}, \boldsymbol{\theta}_d)$

MRI image  $\mathbf{d}$


- Otetaan jokaisen vokselin, jonka luokka on  $k$  intensiteetti Gaussisesta jakaumasta

$$p(\mathbf{d}|\mathbf{l}, \boldsymbol{\theta}_d) = \prod_n \mathcal{N}(d_n | \mu_{l_n}, \sigma_{l_n}^2)$$

$$\boldsymbol{\theta}_d = (\mu_1, \dots, \mu_K, \sigma_1^2, \dots, \sigma_K^2)^T$$


$$\mathcal{N}(d|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left[-\frac{(d-\mu)^2}{2\sigma^2}\right]$$

# Segmentointi



- Käytetään Bayesin sääntöä: 
$$p(\mathbf{l}|\mathbf{d}, \boldsymbol{\theta}) = \prod_n p(l_n|d_n, \boldsymbol{\theta})$$
$$p(l_n|d_n, \boldsymbol{\theta}) \propto \mathcal{N}(d_n|\mu_{l_n}, \sigma_{l_n}^2) \pi_{l_n}$$



# Parametrien estimoinnista



- Etsitään likelihood funktion maksimoivat parametrit EM-algoritmia käyttäen

$$\begin{aligned}\hat{\theta} &= \arg \max_{\theta} p(\mathbf{d}|\theta) \\ &= \arg \max_{\theta} \log p(\mathbf{d}|\theta)\end{aligned}$$




# Parametrien estimointi pähkinäkuoressa



- Luokitellaan kuvan vokselit tämänhetkisten parametriestimaattien perusteella

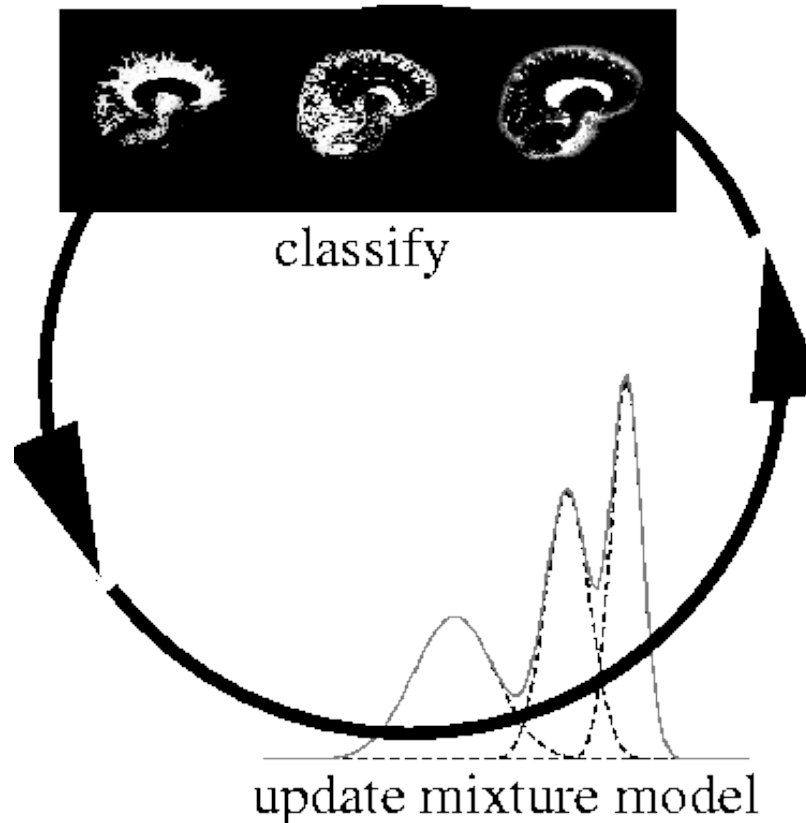


# Parametrien estimointi pähkinänkuoressa




- Päivitetään parametrit tämänhetkisen luokittelun mukaan

# Parametrien estimointi pähkinänkuoressa




- Toistetaan parametrien iterointikaavoja
- Jokainen iteraatio vie kohti maksimia

# Esimerkki



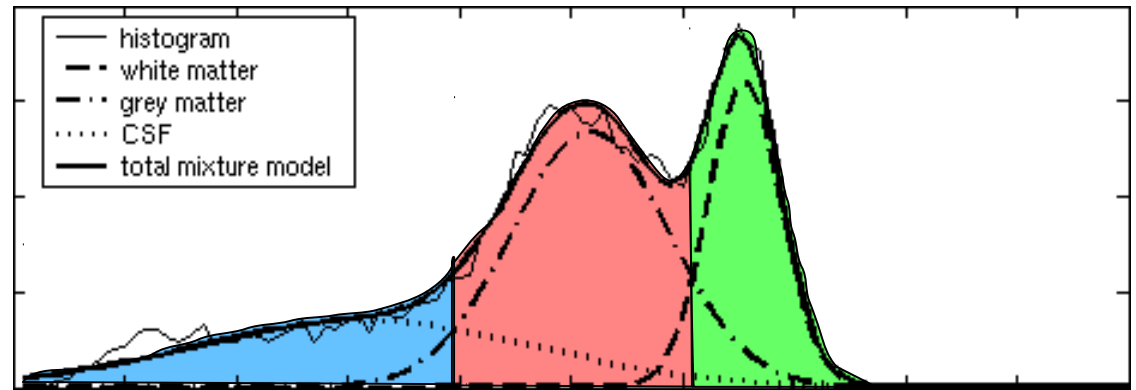
# Esimerkki



white matter

CSF

gray matter



# Pointit

- Aivojen automaattinen segmentointi keskeinen ongelma
- Manuaaliset segmentoinnit vievät aikaa ja segmentoinnin laatu vaihtelee segmentoijasta riippuen
- Bayesialaisilla malleilla saadaan täysin automaattisia segmentointeja