

Képszegmentáló eljárások



Orvosi képdiagnosztika 2019 ősz

Képszegmentálás

- Anatómiai részek elkülönítés: pl. csontok, szív, erek, szürke-fehér állomány, stb
- Vizsgálandó terület körbehatárolása: pl. tüdőterület
- Elváltozások minél pontosabb körülhatárolása
- ...
- Nehézségek:
 - elmosott határok,
 - nem megfelelő felbontás
 - Intenzitás egyenetlenség
 - ...


Képszegmentálás

- Anatómiai részek körülhatárolása



Képszegmentálás

Elváltozás pontos körülhatárolása




Képszegmentálás

- Régió alapú
 - A régió belüli hasonlóságot, ill. a régiók közötti különbségeket használja
 - Intenzitás alapján (küszöbözés)
 - Klaszterezés
 - Textura alapon
 - Régió növesztés, régió hasítás, összeolvasztás
 - Watershed
 - Él alapú, Gradiens alapon Prewitt, Sobel, Kirsch, Canny
- Él alapú
 - Kontúr alapján, élkeresés, derivált, második derivált,
 - Dinamikus programozás
 - Hough traszformáció: egyenes, kör, általános körvonal
- Pixel (voxel) (és környezete) alapú (osztályozás)
 - Tanuló rendszerek, neuronhálók, deep hálók
- ...Statikus, dinamikus, temporális

Képszegmentálás (élek alapján)

Kontúr, élek, alapján



Kezdeti kontúrponatok meghatározása (pl. élkiemelő szűrők),
majd ezekből összefüggő kontúrvonal

Képszegmentálás (élek alapján)

- **Élkiemelő szűrők**

Lineáris szűrők: Sobel, Prewitt, Canny, LoG, ...

Lokális pixel-intenzitás gradiensek alapján $f(x,y)$ -nál a gradiens abszolút értéke és a gradiens iránya

$$|G| = \sqrt{G_x^2 + G_y^2} = \sqrt{\left[\left(\frac{\partial f}{\partial x}\right)^2 + \left(\frac{\partial f}{\partial y}\right)^2\right]}$$

$$D = \tan^{-1}\left(\frac{G_y}{G_x}\right)$$

Sobel operátor G_x és G_y számításához

$$\begin{array}{cccccc} -1 & -2 & -1 & -1 & 0 & 1 \\ 0 & 0 & 0 & -2 & 0 & 2 \\ 1 & 2 & 1 & -1 & 0 & 1 \end{array}$$

Éldetektálás példa




FIGURE 7 Edge detection using Sobel operator. (A) Original angiography image showing blood vessels, (B) edge magnitude image obtained with a 3×3 Sobel mask, (C) edge image thresholded with a low threshold (300), (D) edge image thresholded with a high threshold (600).

Éldetektálás + határvonal követés

- Határvonal követés

Az éldetektáló eljárás intenzitás és irány értékeket produkál ,
de nem feltétlenül összefüggő kontúrt
Egy egyszerű határvonal követő eljárás

$e(x, y)$ él intenzitása $\phi(x, y)$ él iránya



$\mathbf{b}_j \rightarrow \mathbf{b}_{j+1}$ két szomszédos pixel

az alábbi feltételek szerint

$$\begin{aligned} |e(\mathbf{b}_j) - e(\mathbf{b}_{j+1})| &< T_1, \\ |\phi(\mathbf{b}_j) - \phi(\mathbf{b}_{j+1})| \bmod 2\pi &< T_2, \\ |e(\mathbf{b}_j)| &> T, \\ |e(\mathbf{b}_{j+1})| &> T, \end{aligned}$$

Hough transzformáció

Különálló pontokból (éldetektálás eredménye) a pontokra illeszkedő Egyenes (kör, vagy általánosabb alakzat) meghatározása




A Hough transzformáció alapelve

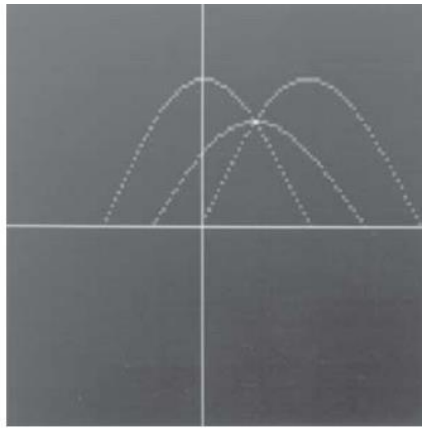
Hough transformáció

- Transzformációs módszerek
 - Egy (binarizált) ponthoz egy sinusoid tartozik
 - Többhöz meg több sinusoid összege:

$$H(\theta, r) = \sum_{x, y \in O} \delta \left([x, y] \cdot \begin{bmatrix} \cos(\theta) \\ \sin(\theta) \end{bmatrix} - r \right)$$




(a) Three dots: upper left, center, lower right



(b) Hough transform of dots




(c) Straight line




(d) Hough transform of line

Hough transformáció


Egy példa 2 egyenessel



Hough transformáció pl.




Hough transformáció pl.



Általánosított Hough transzformáció


Egyéb, előre definiált alakzat detektálása




él-kép, amin ismert
sugarú kört keresünk

2D Hough-tér, ahol minden
élpontnak egy, a potenciális
középpontokat tartalmazó kör
felel meg

Általánosított Hough transzformáció



él-kép



maximumhely(ek) a Hough-térben → a detektált kör(ök) középpontja(i)

Létezik általánosabb alak detektáló verzió is

Régió alapú szegmentálás

- Matematikai definíció:
 - $\bigcup R_i = I$
 - Minden R_i topológiailag összefüggő
 - $R_i \cap R_j = \{\emptyset\} \mid \forall (i \neq j)$
 - Minden régió homogén (az adott célfaladat értelmében)
 - Nincs két olyan (topológiailag szomszédos) régió, melyek uniója homogén lenne
- Leggyakrabban alkalmazott eljárások:
 - Régió növesztés
 - Régiók darabolása és egyesítése

Régió növesztés

- Algoritmus:
 1. Kiválasztunk N db magpontot, ezek a kezdeti régiók
($R_i^{(0)} = s_i$)
 2. Iteratívan (k felett), amíg van változás:
 - 2.1. Minden i -re megnézzük $R_i^{(k-1)}$ szomszédos, még régiókban nem osztott pixeleit, hogy azokat hozzávonva homogén marad-e
 - 2.2. Amelyekre igen, azokat összevonjuk
- Tulajdonságok:
 - Közel sem optimális mohó eljárás
 - Magpontokon, régiók, illetve pixelek sorrendezésén - heurisztikákon sok múlik

Régió darabolás és egyesítés

- Algoritmus:

1. $R_1^{(0)} = I$

2. Ciklus amíg $\exists i: \neg P_e \left(R_i^{(k)} \right)$

- 2.1. Adott régiót két részre bontjuk a leginkább „problémás” pixel mentén egy vágással

3. Ciklus amíg $\exists i \neq j: P_{gy} \left(R_i^{(k)} \cup R_j^{(k)} \right)$ és $N \left(R_i^{(k)}, R_j^{(k)} \right)$

$$R_i^{(k+1)} := R_i^{(k)} \cup R_j^{(k)} \quad \text{és} \quad R_j^{(k+1)} := \{\emptyset\}$$

- Problémák:

- Sorrend és heurisztika függő, de már kevésbé
- Nehezebben számolható

Régió darabolás és egyesítés

- Algoritmus:

1. $R_1^{(0)} = I$

2. Ciklus amíg $\exists i: \neg P_e(R_i^{(k)})$

- 2.1. Adott régió „probléma” megengedőbb homogenitási kritériummal eginkább

3. Ciklus amíg $\exists i \neq j: P_{gy}(R_i^{(k)} \cup R_j^{(k)})$ és $N(R_i^{(k)}, R_j^{(k)})$

$$R_i^{(k+1)} := R_i^{(k)} \cup R_j^{(k)}$$

- Problémák:

- Sorrend és heurisztika függő, de már kevésbé
- Nehezebben számolható

Erősebb homogenitási
kritérium

Megengedőbb homogenitási
kritérium

Szomszédosság logikai fgv-e

Textúra alapú analízis

- Textúra definíciója – két megközelítés:
 - Strukturális: egyszerű texelek halmaza, melyek szabályszerűen ismétlődnek
 - Statisztikai: intenzitások (térbeli) eloszlásának kvantitatív mértéke


Generálásnál a strukturális, míg felismerésnél a statisztikai megközelítés dominál

- Emberi értelmezésnél fontos szerepük van
 - Gépi látás eszközeivel viszont nehéz feladat a kezelésük
 - Nehéz jó textúra leírókat definiálni


Textúra alapú analízis példa




(a)



(b)



(c)



(d)

Textúra statisztikai leírása

- Élek sűrűsége és iránya:

Korrelált egy-egy homogén textúrájú régióon belül

Együttes hisztogramjuk pár kiemelkedően nagy értékkel bír

- Fourier spektrum alapú módszerek:

Periodikusan ismétlődő finom mintázat impulzusokat generál a spektrumképen


- Autokorrelációs eljárások:

$$\rho(m, n) = \frac{\sum_j \sum_k I(j, k) \cdot I(j + m, k + n)}{\sum_j \sum_k I^2(j, k)}$$


Textúra - autokorreláció



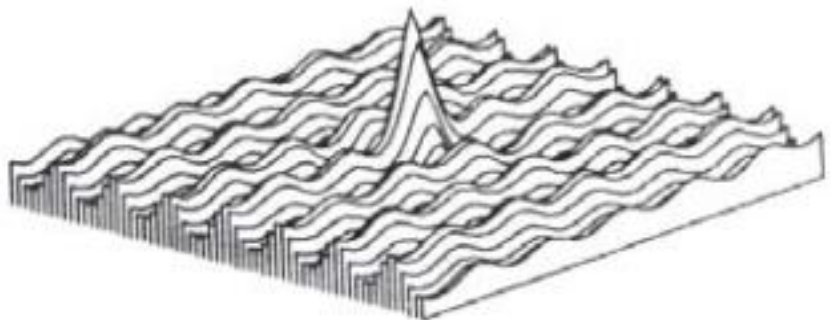
(a) Sand



(b) Grass



(c) Wool



(d) Raffia

Függőségi mátrix alapú megközelítés

- Ko-okkurencia mátrix:

$$C_d(a, b) = \left| \left\{ (x, y), (v, w) \in M \times M \left| \begin{array}{l} I(x, y) = a, I(v, w) = b \\ (x, y, v, w) \in d(M) \end{array} \right. \right\} \right|$$

- $d(M)$: adott térbeli elhelyezkedésű pontpárok koordinátáinak halmaza, pl. $(x, y) - (v, w) = T$
- M : vizsgált régió képpontjainak a halmaza


$$N_d(a, b) = \frac{C_d(a, b)}{\sum_{(a, b)} C_d(a, b)} \quad S_d(a, b) = C_d(a, b) + C_{d^*}(a, b)$$

Haralick jellemzők

- Ko-okkurencia mátrixból származtatott statisztikák
 - Energia: $\sum_{(a,b)} N_d^2(a,b)$
 - Entrópia: $-\sum_{(a,b)} \log(N_d(a,b)) \cdot N_d(a,b)$
 - Kontraszt: $\sum_{(a,b)} (a-b)^2 \cdot N_d(a,b)$
 - Homogenitás: $\sum_{(a,b)} N_d(a,b) / (1 + |a-b|)$
 - Korreláció, χ^2 statisztikai teszt, stb.

Textúra alapú szegmentálás

- Általában régió növesztés / darabolás alapján
 - Régiók hasonlóságát textúra alapú jellemzőkkel definiálja



Küszöbözés (egyszerű eljárások)




FIGURE 2 An example of global thresholding. (A) Original image, (B) histogram of image A, (C) result of thresholding with $T = 127$, (D) outlines of the white cells after applying a 3×3 Laplacian to the image shown in C.

- Globális küszöbözés







$$g(x, y) = \begin{cases} 1 & \text{if } (x, y) > T \\ 0 & \text{if } (x, y) \leq T \end{cases}$$

- Nagy homogén területek, egyenletes intenzitásértékek


- Zajos, kis intenzitáskülönbség
- Erősen változó háttérintenzitás

Intenzitás alapú képszegmentálás

Intenzitás alapján, hisztogramban küszöbözéssel



Lokális, adaptív küszöbözés



A kép hisztogram
módosítása
szűréssel
(mediánszűrés),
majd küszöbözés


FIGURE 4 Median filtering as a preprocessing step for thresholding; (A) original autoradiography image, (B) result of a 7×7 median filter, (C) result of a 9×9 median filter. Corresponding image histograms are shown on the right.

Képszegmentálás

- Küszöbözéssel
 - Hisztogram „nevezetes” pontjai alapján: szélsőértéknél
 - Zaj hatása, simító előfeldolgozás
- Optimális küszöbözés
 - **Paraméteres** (Gauss függvények összegeként modellezzük)
Feladat: hány Gauss, és milyen paraméterekkel
 - **Nemparaméteres** (valamilyen mérőszámok definiálása, ennek megfelelő küszöbérték(ek))
- **Paraméteres:** pl. Gauss függvények összegeként modellezzük

$$p(g) = \frac{P_1}{\sqrt{2\pi}\sigma_1} e^{-\frac{(g-\mu_1)^2}{2\sigma_1^2}} + \frac{P_2}{\sqrt{2\pi}\sigma_2} e^{-\frac{(g-\mu_2)^2}{2\sigma_2^2}} = P_1 p_1(g) + P_2 p_2(g)$$

Küszöb meghatározása



$$\alpha T^2 + \beta T + \gamma = 0$$

$$\alpha = \sigma_1^2 - \sigma_2^2,$$

$$\beta = 2(\mu_1\sigma_2^2 - \mu_2\sigma_1^2),$$

$$\gamma = \mu_2^2\sigma_1^2 - \mu_1^2\sigma_2^2 + \sigma_1^2\sigma_2^2 \ln\left(\frac{\sigma_1 P_1}{\sigma_2 P_2}\right)$$

Ha $\sigma_1 = \sigma_2$

$$T = \frac{\mu_1 + \mu_2}{2} + \frac{\sigma^2}{\mu_1 - \mu_2} \ln\left(\frac{P_2}{P_1}\right)$$

Két Gauss metszéspontjának meghatározása elemi műveletekkel

EM algoritmus

- Alapötlet:

- Adott egy ML becslési probléma:

$$\theta^* = \arg \max_{\theta} \left\{ l(\theta) = \sum_i \log \left(p \left(x^{(i)} \mid \theta \right) \right) \right\}$$

- Könnyebb lenne ha ismernénk bizonyos látns változók értékeit:


$$\theta^* = \arg \max_{\theta} \left\{ l(\theta) = \sum_i \log \left(p \left(x^{(i)}, z^{(i)} \mid \theta \right) \right) \right\}$$

EM algoritmus

- Jensen egyenlőtlenség:
 - Legyen f egy konvex függvény, X pedig egy v.v.
 - Tétel: $E\{f(X)\} \geq f(E\{X\})$

Pl. $p(X=a)=0,5$

$p(X=b)=0,5$



EM algoritmus

- Végezzük el a bővítést:

$$\begin{aligned} l(\theta) &= \sum_i \log \left(p \left(x^{(i)} \mid \theta \right) \right) = \sum_i \log \left(\sum_{z^{(i)}} p \left(x^{(i)}, z^{(i)} \mid \theta \right) \right) \\ &= \sum_i \log \left(\sum_{z^{(i)}} Q_i \left(z^{(i)} \right) \left(\frac{p \left(x^{(i)}, z^{(i)} \mid \theta \right)}{Q_i \left(z^{(i)} \right)} \right) \right) \quad Q_i \text{ egy eloszlás} \\ &\geq \sum_i \sum_{z^{(i)}} Q_i \left(z^{(i)} \right) \log \left(p \left(x^{(i)}, z^{(i)} \mid \theta \right) / Q_i \left(z^{(i)} \right) \right) \end{aligned}$$

Mivel log konkáv, a zárójelen belüli rész meg egy várható érték:

$$\sum_i \sum_{z^{(i)}} Q_i \left(z^{(i)} \right) \cdot \left(p \left(x^{(i)}, z^{(i)} \mid \theta \right) / Q_i \left(z^{(i)} \right) \right) = \mathbb{E}_{z^{(i)} \sim Q_i} \left\{ p \left(x^{(i)}, z^{(i)} \mid \theta \right) / Q_i \left(z^{(i)} \right) \right\}$$

EM algoritmus

Mi legyen $Q_i(z^{(i)})$ definíciója:

- Válasszuk meg úgy, hogy a Jensen egyenlőtlenség éles legyen adott θ esetén:

$$p(x^{(i)}, z^{(i)} | \theta) / Q_i(z^{(i)}) = c \in \mathbb{R}$$

$$Q_i(z^{(i)}) \propto p(x^{(i)}, z^{(i)} | \theta)$$

$$Q_i(z^{(i)}) = p(x^{(i)}, z^{(i)} | \theta) / \sum p(x^{(i)}, z^{(i)} | \theta)$$

$$Q_i(z^{(i)}) = p(x^{(i)}, z^{(i)} | \theta) / \int p(x^{(i)} | \theta) = p(z^{(i)} | x^{(i)}, \theta)$$

Tehát Q a z v.v.-k posteriorja

EM algoritmus

- A likelihood alsó becslését kell maximalizálni (iteratívan):

- Expectation lépés:

$$Q_i^{(t)}(z^{(i)}) = p(z^{(i)} | x^{(i)}, \theta^{(t)})$$

- Maximization lépés:

$$\theta^{(t+1)} = \arg \max_{\theta} \left(\sum_i \sum_{z^{(i)}} Q_i^{(t)}(z^{(i)}) \log \left(p(x^{(i)}, z^{(i)} | \theta) / Q_i^{(t)}(z^{(i)}) \right) \right)$$

- HF: belátni, hogy konvergens

EM algoritmus értelmezése

- Interpretálható egy block coordinate ascent-ként is:

$$J(Q, \theta) = \sum_i \sum_{z^{(i)}} Q_i^{(t)}(z^{(i)}) \log \left(p(x^{(i)}, z^{(i)} | \theta) / Q_i^{(t)}(z^{(i)}) \right)$$

- Expectation lépés:

$$Q^{(t+1)} = \arg \max_Q \left\{ J(Q, \theta^{(t)}) \right\}$$

- Maximization lépés:


$$\theta^{(t)} = \arg \max_{\theta} \left\{ J(Q^{(t+1)}, \theta) \right\}$$

EM algoritmus mintapélda

Feladat a Gauss eloszlások paramétereinek becslése

Itt csak μ_1 és μ_2 becslése

$$y_i = \langle x_i, z_{i1}, z_{i2} \rangle$$



x_i megfigyelhető

z_{ij} nem megfigyelhető

De: $z_{ij} = 1$, ha x_i -t a

j -edik Gauss generálta

Kiinduló értékek

$$h = \langle \mu_1, \mu_2 \rangle$$

Két egymást követő lépés:

- Várható érték képzés
- Maximum keresés

$$\begin{aligned} E[z_{ij}] &= \frac{p(x = x_i | \mu = \mu_j)}{\sum_{n=1}^2 p(x = x_i | \mu = \mu_n)} \\ &= \frac{e^{-\frac{1}{2\sigma^2}(x_i - \mu_j)^2}}{\sum_{n=1}^2 e^{-\frac{1}{2\sigma^2}(x_i - \mu_n)^2}} \end{aligned}$$

$$\mu_j \leftarrow \frac{\sum_{i=1}^m E[z_{ij}] x_i}{\sum_{i=1}^m E[z_{ij}]}$$

A likelihood függvény egy mintára

$$P(Y|h') = p(x^{(l)}, z^{(l)} | \boldsymbol{\mu}) \quad \text{ahol } \boldsymbol{\mu} = [\mu_1 \ \mu_2]^T$$

$$P(Y|h') = p(x^{(l)}, z^{(l)} | \boldsymbol{\mu}) = \prod_{i=1}^k p(x^{(l)} | \mu_i)^{z_i^{(l)}} \quad \text{jelenleg } k = 2$$

L mintára, ha azok függetlenek

$$P(Y|h') = p(X, Z | \boldsymbol{\mu}) = \prod_{l=1}^L \prod_{i=1}^k p(x^{(l)} | \mu_i)^{z_i^{(l)}}$$

A log likelihood fv:

$$\begin{aligned} \log P(Y|h') &= \log p(X, Z | \boldsymbol{\mu}) = \sum_{l=1}^L \sum_{i=1}^k \log \left(p(x^{(l)} | \mu_i)^{z_i^{(l)}} \right) \\ &= \sum_{l=1}^L \sum_{i=1}^k z_i^{(l)} \log \left(p(x^{(l)} | \mu_i) \right) \end{aligned}$$

Helyette

$$E \left\{ \log P(Y|h') \right\} = \sum_{l=1}^L \sum_{i=1}^k E \left\{ z_i^{(l)} \right\} \log \left(p(x^{(l)} | \mu_i) \right)$$

Várhatóérték-képzés

$$\begin{aligned} E\{z_i^{(l)}\} &= 1 p(z_i^{(l)} = 1) + 0 p(z_i^{(l)} = 0) = p(z_i^{(l)} = 1) \\ &= p(z_i^{(l)} = 1 | x = x^{(l)}) \end{aligned}$$

$$p(i | x = x^{(l)}) = \frac{p(x = x^{(l)} | i) P(i)}{\sum_j p(x = x^{(l)} | j) P(j)} = E\{z_i^{(l)}\}$$

Gauss eloszlás mellett és feltételezve, hogy $P(1)=P(2)$

$$E\{z_i^{(l)}\} = \frac{\exp\left(-\frac{1}{2\sigma^2} \left(x^{(l)} - \mu_1\right)^2\right)}{\sum_j \exp\left(-\frac{1}{2\sigma^2} \left(x^{(l)} - \mu_j\right)^2\right)}$$

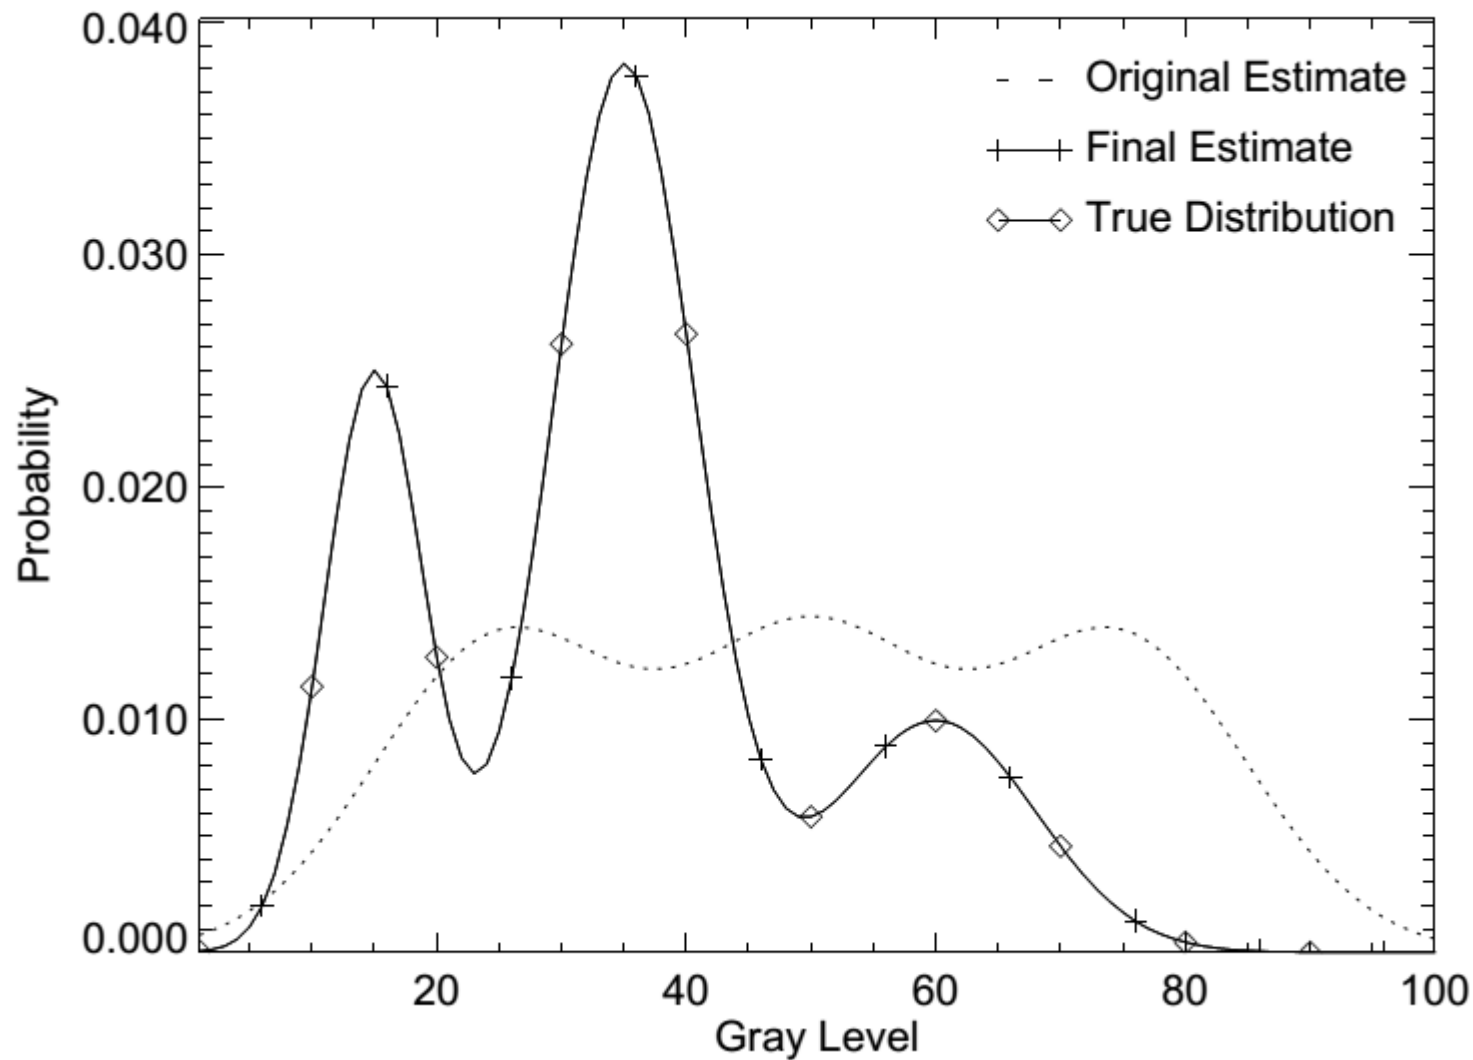
Behelyettesítve a log likelihood fv-be és elvégezve a szélsőérték-keresést

$$\mu_1 = \frac{\sum_l E\{z_1^{(l)}\} x^{(l)}}{\sum_l E\{z_1^{(l)}\}}; \quad \mu_2 = \frac{\sum_l E\{z_2^{(l)}\} x^{(l)}}{\sum_l E\{z_2^{(l)}\}}$$


Kölcsönös függés
Iteratív eljárásra
van szükség

$$E\{z_i^{(l)}\} = \frac{\exp\left(-\frac{1}{2\sigma^2}\left(x^{(l)} - \mu_1\right)^2\right)}{\sum_j \exp\left(-\frac{1}{2\sigma^2}\left(x^{(l)} - \mu_j\right)^2\right)}$$

Illusztratív példa EM alapú Gauss paraméterbecslésre




Tüdőszegmentálás



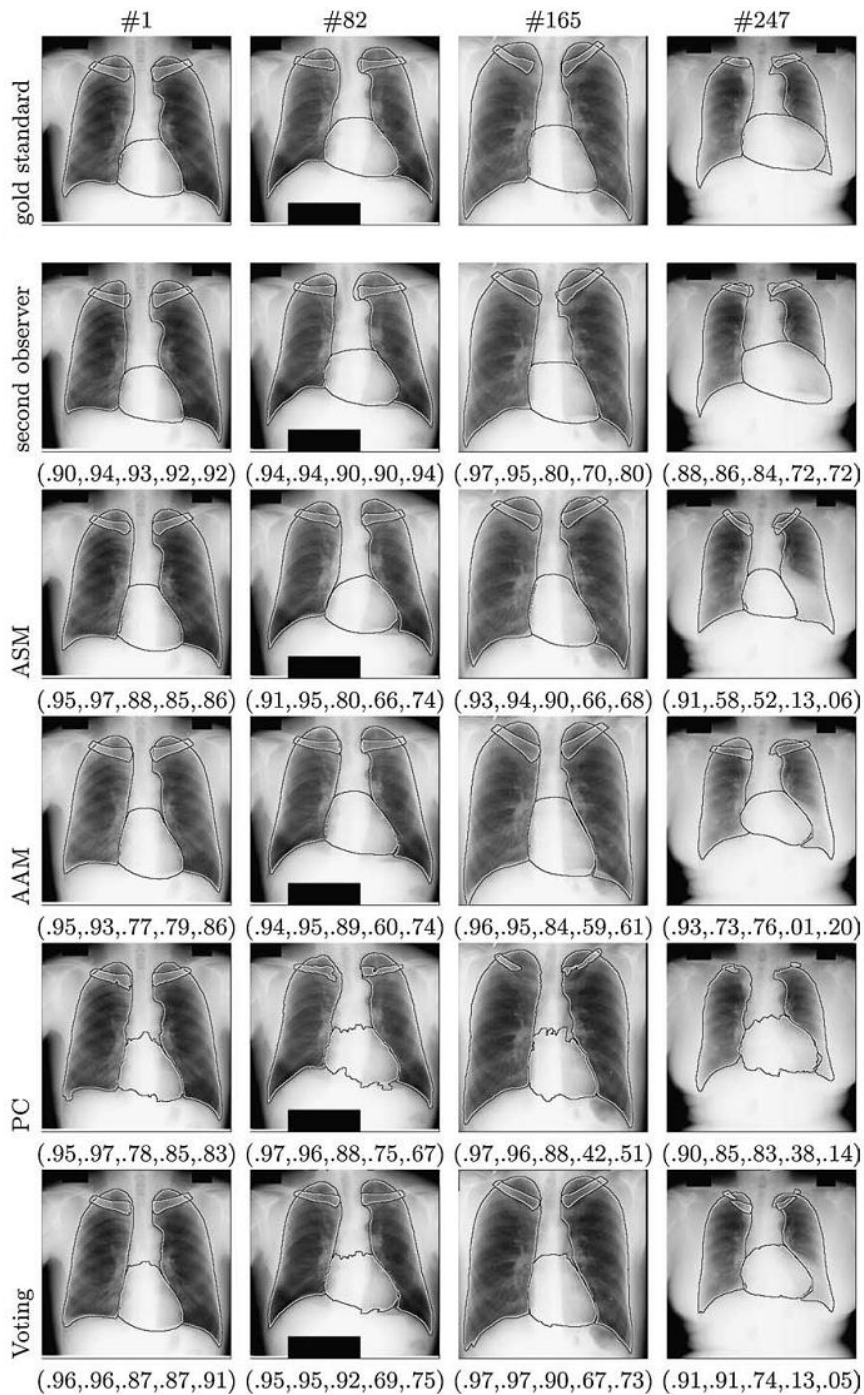
eredeti kép szegmentálás 7 különböző eljárással összehasonlítás
valódi negatív: fehér, valódi pozitív:világos szürke,
false pozitív: sötét szürke, fals negatív: fekete

Tüdőszegmentálás




(h)


Snake



Orvosi képek szegmentálása



(b)



(b)



(c)



(d)



(e)



(f)

Orvosi képek szegmentálása



(b)



(c)



Tüdő-és szív-szegmentálás

- Deformálható modell (ASM)

