Képszegmentáló eljárások

Orvosi képdiagnosztika 2017 ősz

9. ea. 2015 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

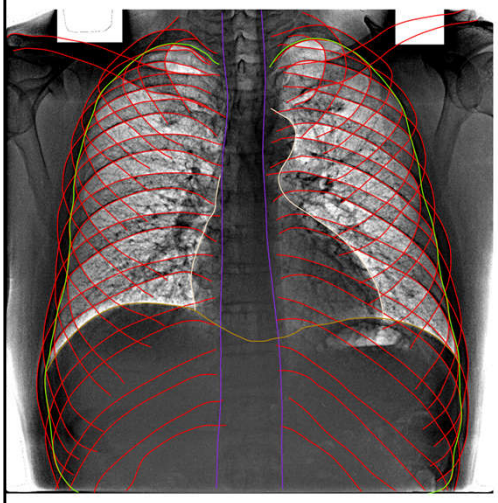

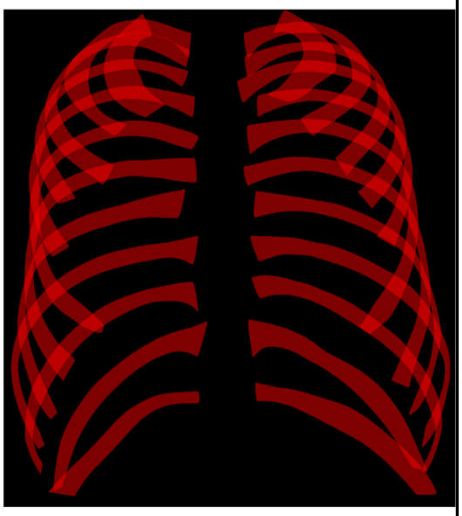

Képszegmentálás

Elváltozás pontos körülhatárolása

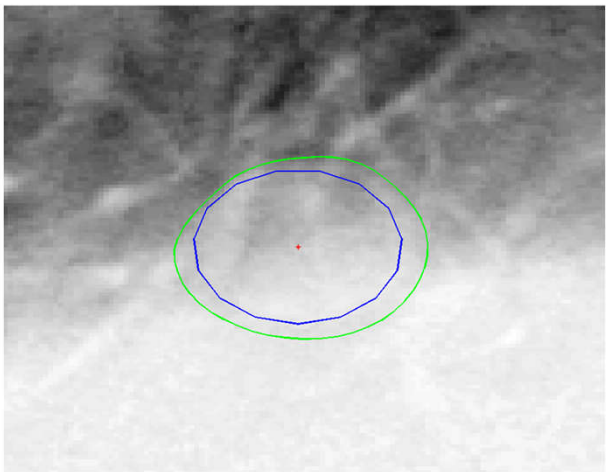

Képszegmentálás

- Régió alapú
  - A régión 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

Lokális, globális küszöbözés, dinamikus küszöbözés, adaptív küszöbözés

Küszöbözés (egyszerű eljárások)

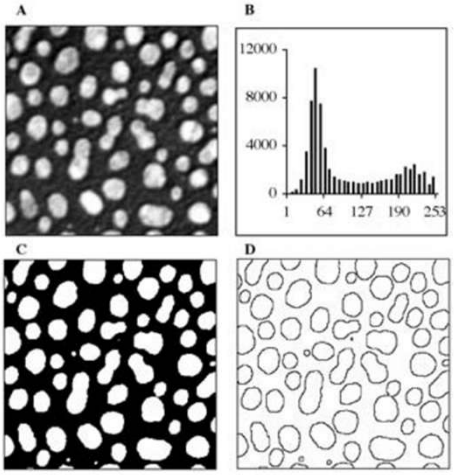

FIGURE 2 An example of global thresholding. (A) Original image, (B) histogram of image A, (C) result of thresholding with $T = 127$, (D) outlines of the white cells after applying a 3×3 Laplacian to the image shown in C.

- 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

Képszegmentálás

Intenzitás alapján, hisztogramban küszöbözéssel

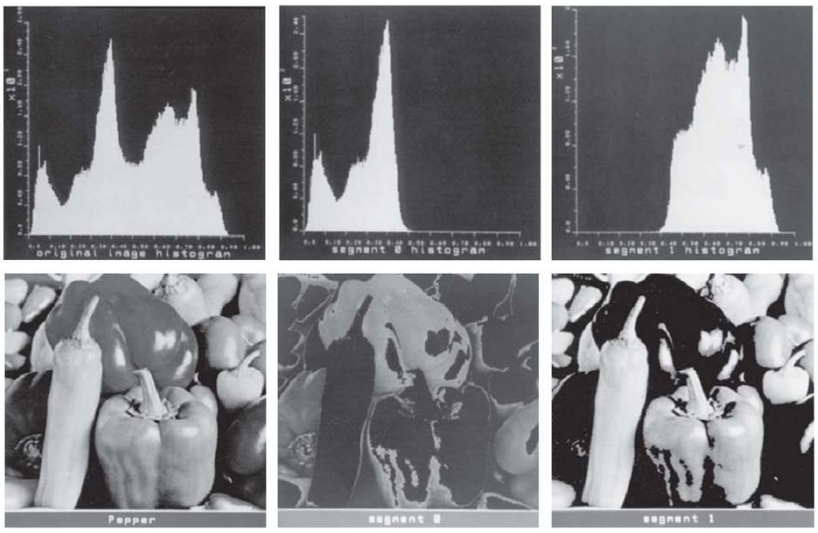

Lokalis, adaptív küszöbözés

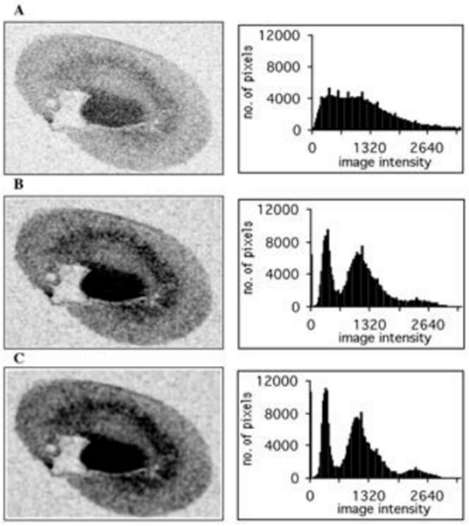

FIGURE 4 Median filtering as a preprocessing step for thresholding; (A) original autoradiography image, (B) result of a 7 × 7 median filter, (C) result of a 9 × 9 median filter. Corresponding image histograms are shown on the right.

A kép hisztogram módosítása szűréssel (mediánszűrés), majd küszöbözés

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

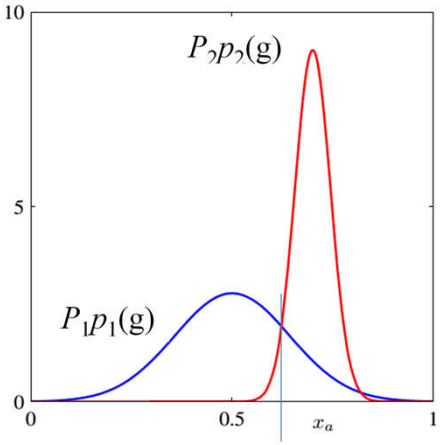

$$\alpha T^2 + \beta T + \gamma = 0$$

$$\begin{aligned} \alpha &= \sigma_1^2 - \sigma_2^2, \\ \beta &= 2(\mu_1\sigma_2^2 - \mu_2\sigma_1^2)\,, \\ \gamma &= \mu_2^2\sigma_1^2 - \mu_1^2\sigma_2^2 + \sigma_1^2\sigma_2^2 \ln(\frac{\sigma_1 P_1}{\sigma_2 P_2}) \end{aligned}$$

Ha σ_1=σ_2

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

Két Gauss metszéspontjának meghatározása elemi műveletekkel

EM algoritmus

A feladat: egy valószínűség eloszlás valmilyen Θ paraméterét(vektorát) akarjuk becsülni részlegesen megfigyelhetőadatok alapján.
A megfigyelések: $X=\{\mathbf{x}_1, \mathbf{x}_2, \ldots, \mathbf{x}_L\}$ ismert
Nem ismert $Z=\{\mathbf{z}_1, \mathbf{z}_2, \ldots, \mathbf{z}_L\}$

A teljes adathalmaz: $Y = X \cup Z$
Kiinduló hipotézis a becsülni kívánt ismeretlen paraméterről *h*
Ezt feltételezve tudunk becslést adni az ismeretlen paraméterre

Feladat a Gauss eloszlások paramétereinek becslése

Itt csak μ_1 és μ_2 becslése

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

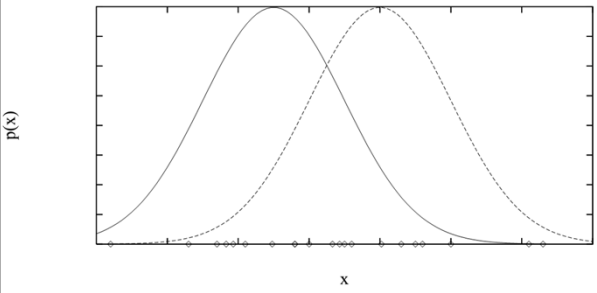

x_i megfigyelhető

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

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

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

A likelihood függvény egy mintára

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

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

L mintára, ha azok függetlenek

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

A log likelihood fv:

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

$$= \sum_{l=1}^{L}\sum_{i=1}^{k} z_i^{(l)} \log\left(p(x^{(l)}\middle|\mu_i)\right)$$

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

Várhatóérték-képzés

$$E\left\{z_i^{(l)}\right\} = 1\, p(z_i^{(l)} = 1) \;\; + 0\, p(z_i^{(l)} = 0) = p(z_i^{(l)} = 1)$$

$$= p(z_i^{(l)} = 1 \Big| x = x^{(l)})$$

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

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

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

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

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

Kölcsönös függés
Iteratív eljárásra van szükség

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

Illusztratív példa EM alapú Gauss paraméterbecslésre

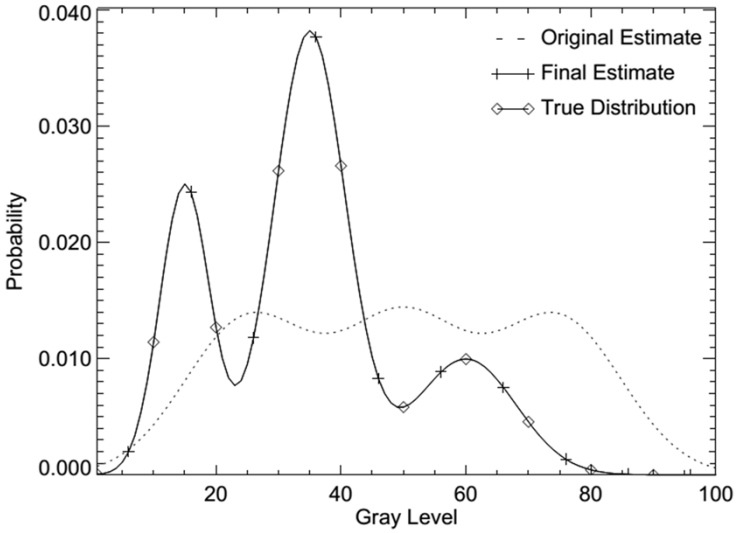

EM algoritmus (általános)

EM algoritmus

Keresett paramétervektor θ

$Y = X \cup Z$ $X=\{\mathbf{x}_1, \mathbf{x}_2, \ldots, \mathbf{x}_L\}$ $Z=\{\mathbf{z}_1, \mathbf{z}_2, \ldots, \mathbf{z}_L\}$

$$L(X|\theta) = \log\left(P(X|\theta)\right) \cdot \sum_{z \in Z} P(Z|X,\theta) \qquad P(X|\theta) = \frac{P(X,Z|\theta)}{P(Z|X,\theta)}$$

$$L(X|\theta) = \sum_{z} P(Z|X,\theta) \cdot \left(\log\left(P(X,Z|\theta)\right) - \log\left(P(Z|\mathrm{X},\theta)\right)\right)$$

$$L(X|\theta) = E_{z \in Z}\left\{\log\left(P(X,Z|\theta)\right)|X,\theta\right\} - E_{z \in Z}\left\{\log\left(P(Z|\mathrm{X},\theta)\right)|X,\theta\right\}$$

Entrópiás interpretáció

Régió alapú szegmentálás

- Matematikai definíció:
  - $\bigcup \mathrm{R}_i = \mathrm{I}$
  - Minden R_i topológiailag összefüggő
  - $\mathrm{R}_i \bigcap \mathrm{R}_j = \{\varnothing\} \big| \forall (i \neq j)$
  - 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 ($\mathrm{R}_i^{(0)} = s_i$)
  2. Iteratívan (k felett), amíg van változás:
     2.1. Minden i-re megnézzük $\mathrm{R}_i^{(k-1)}$ 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. $\mathrm{R}_1^{(0)} = \mathrm{I}$
  2. Ciklus amíg $\exists \mathrm{i}: \neg \mathrm{P}_e\left(\mathrm{R}_i^{(k)}\right)$
     2.1. Adott régiót két részre bontjuk a leginkább „problémás” pixel mentén egy vágással
  3. Ciklus amíg $\exists \mathrm{i} \neq \mathrm{j}: \mathrm{P}_{gy}\left(\mathrm{R}_i^{(k)} \cup \mathrm{R}_j^{(k)}\right)$ és $N\left(\mathrm{R}_i^{(k)}, \mathrm{R}_j^{(k)}\right)$
     $\mathrm{R}_i^{(k+1)} := \mathrm{R}_i^{(k)} \cup \mathrm{R}_j^{(k)}$ és $\mathrm{R}_j^{(k+1)} := \{\varnothing\}$
- Problémák:
  – Sorrend és heurisztika függő, de már kevésbé
  – Nehezebben számolható

Régió darabolás és egyesítés

- Algoritmus:
  1. $R_1^{(0)} = I$
  2. Ciklus amíg $\exists i: \neg P_e\left(R_i^{(k)}\right)$
     2.1. Adott rég … eginkább „problém … ással
  3. Ciklus amíg $\exists i \neq j: P_{gy}\left(R_i^{(k)} \cup R_j^{(k)}\right)$ és $N\left(R_i^{(k)}, R_j^{(k)}\right)$

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

Erősebb homogenitási kritérium

Megengedőbb homogenitási kritérium

Szomszédosság logikai fgv-e

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

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

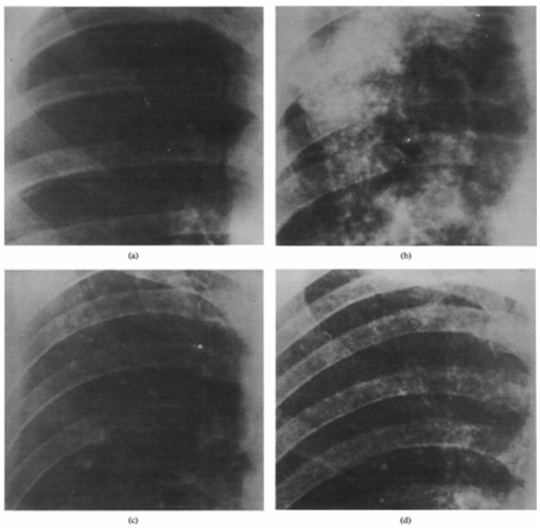

Textúra statisztikai leírása

- Élek sűrűsége és iránya:
  Korrelált egy-egy homogén textúrájú régión belül
  Együttes hisztogramjuk pár kiemelkedően nagy értékkel bír
- Fourier spektrum alapú módszerek:
  Periodikusan ismétlődő finom mintázat impulzusokat generál a spektrumképen
- Autokorrelációs eljárások:

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

Normált autokorreláció: +1 és -1 közötti értékű
Belátható „½(a+b)^2>=0 minden a és b” -ből

Textúra - autokorreláció

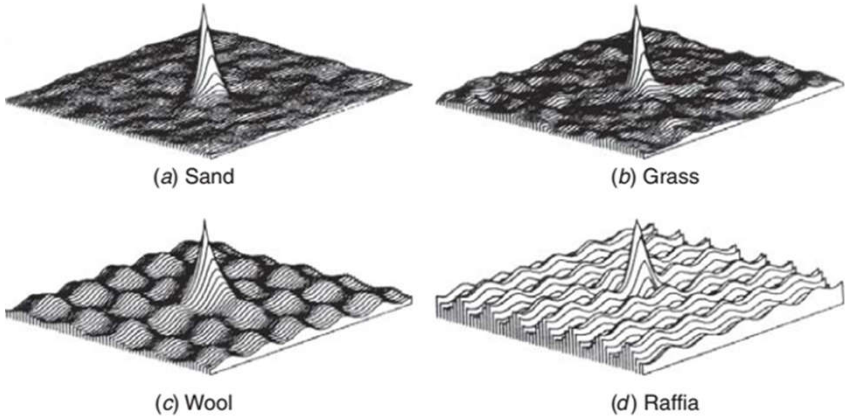

Függőségi mátrix alapú megközelítés

- Ko-okkurencia mátrix:

$$\mathrm{C}_d(\mathrm{a},\mathrm{b}) = \left| \left\{ (x,y),(v,w) \in M \times M \,\middle|\, \begin{matrix} I(x,y)=a, I(v,w)=b \\ (x,y,v,w) \in d(M) \end{matrix} \right\} \right|$$

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

$$\mathrm{N}_d(a,b) = \frac{\mathrm{C}_d(\mathrm{a},\mathrm{b})}{\sum_{(a,b)} \mathrm{C}_d(\mathrm{a},\mathrm{b})} \qquad \mathrm{S}_d(a,b) = \mathrm{C}_d(a,b) + \mathrm{C}_{d^*}(a,b)$$

Haralick jellemzők

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

Law mikrostruktúra mértékei

- Szeparábilis szűrők válaszait méri lokálisan
  - Lokalitás definíciója feladatfüggő
  - Szeparábilis szűrők: 1 d kernelek diadikus szorzata

    pl. L5E5: $[1,4,6,4,1]\cdot[-1,-2,0,2,1]^T$
- Eljárás:
  1. Pixelenként lokálisan 0 várható értékűvé tétele a képnek
  2. Szűrések elvégzése (k. eredménye: F_k)
  3. Textúra energia térkép előállítása:

$$E_k(r,c)=\sum_{(j,i)\in N(r,c)}\left|F_k(i,j)\right|$$

Textúra alapú szegmentálás

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

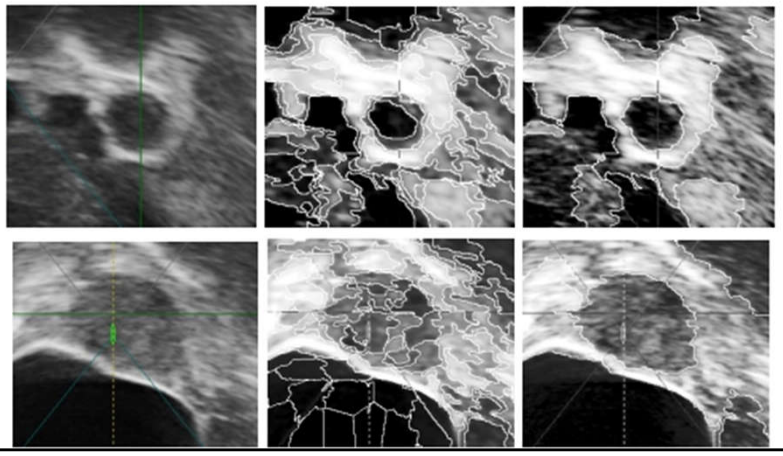

Képszegmentálás (élek alapján)

Kontúr, élek, alapján

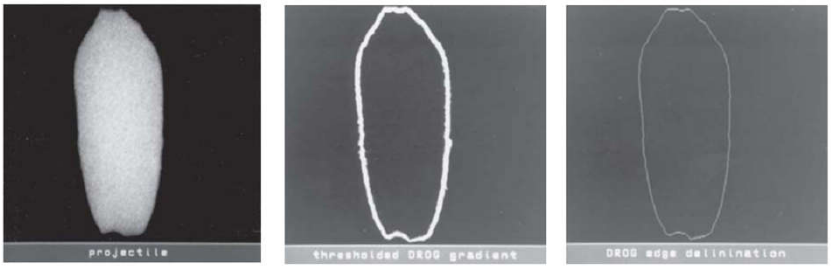

Kezdeti kontúrpontok meghatározása (pl. élkiemelő szűrők), majd ezekből összefüggő kontúrvonal

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

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

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

Sobel operátor G_x és G_y számításához

$$\begin{matrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{matrix} \qquad \begin{matrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{matrix}$$

Éldetektálás példa

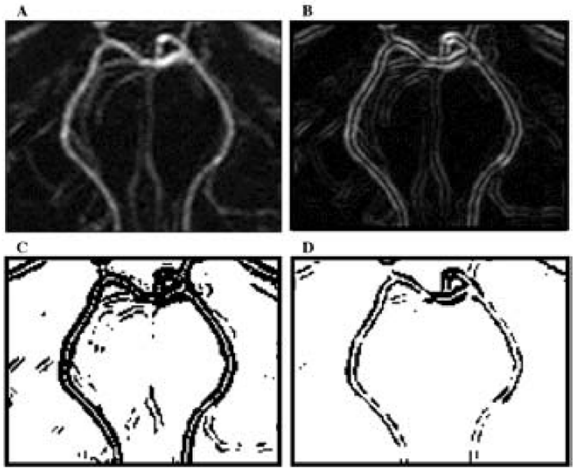

FIGURE 7 Edge detection using Sobel operator. (A) Original angiography image showing blood vessels, (B) edge magnitude image obtained with a 3×3 Sobel mask, (C) edge image thresholded with a low threshold (300), (D) edge image thresholded with a high threshold (600).

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

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

az alábbi feltételek szerint

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

Hough transzformáció

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

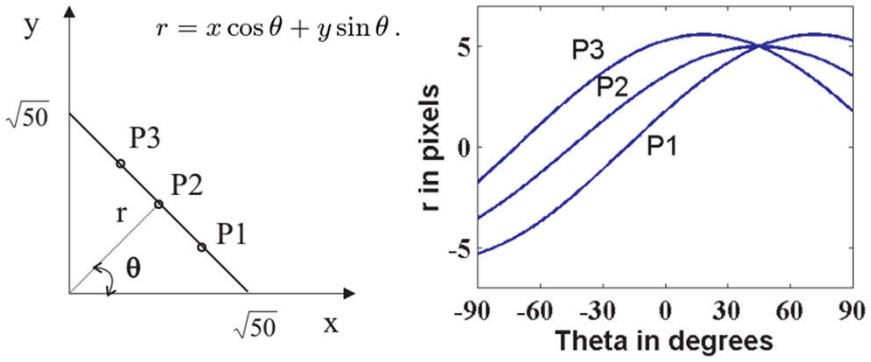

A Hough transzformáció alapelve

Melyik az a pont a Hough térben, melyen az eredeti tér egyenesének összes pontjához tartozó sinusoid átmegy?

Hough transzformáció

- Transzformációs módszerek
  - más tartományba transzformálom a kép egyes pontjait
  - Pl: egy pont a képtérben egy görbét határoz meg. Egy egyenes pontjai a Hough térben az egyes pontokhoz tartozó görbék metszéspontjai. Az egyenest ez a metszépont fogja megadni

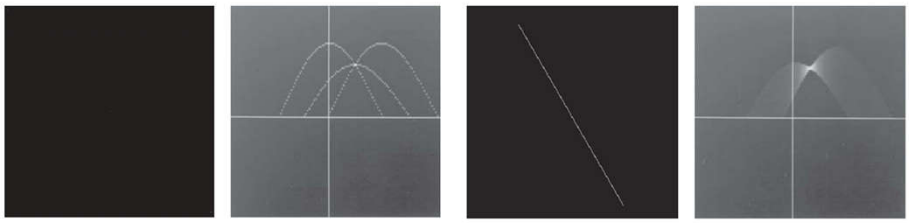

(a) Three dots: upper left, center, lower right (b) Hough transform of dots (c) Straight line (d) Hough transform of line

Hough transzformáció

Egy példa 2 egyenessel

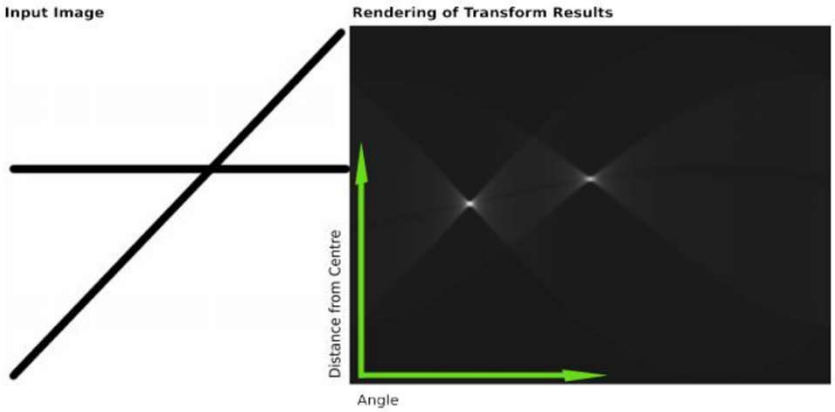

Hough transzformáció

Egy példa

A képen 5 egyenes található (4 oldal + 1 átló)

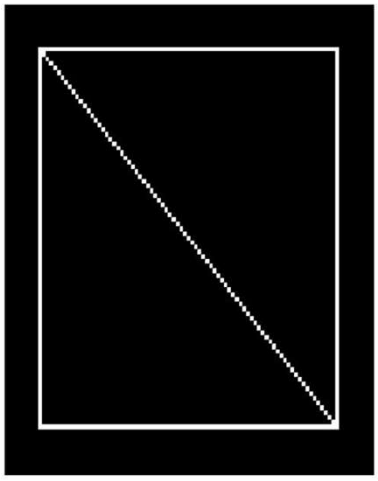

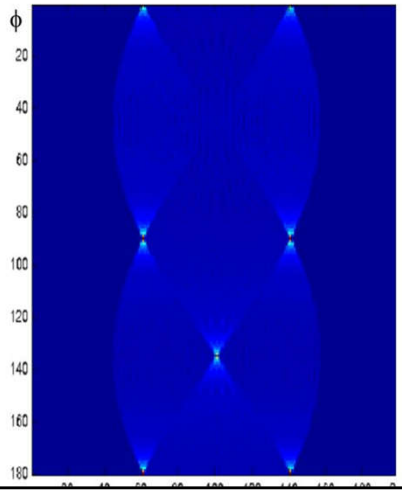

Általánosított Hough transzformáció

Egyéb, előre definiált alakzat detektálása

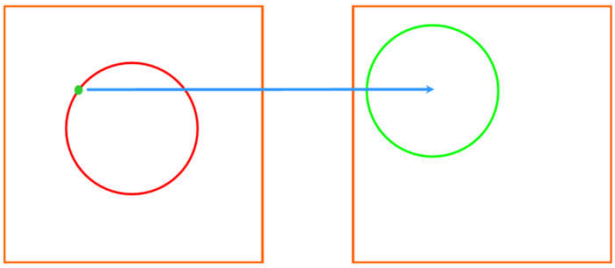

él-kép, amin ismert sugarú kört keresünk

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

Egy ponthoz itt az adott pontot tartalmazó r sugarú körök középpontjait rendeljük!

Általánosított Hough transzformáció

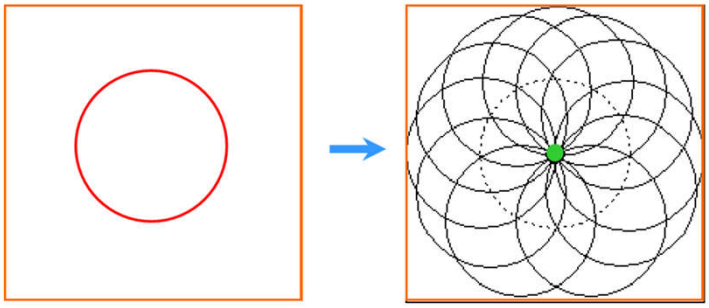

él-kép

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

Létezik általánosabb alak detektáló verzió is

Képszegmentálás klaszterezéssel

- Klaszterezés, osztályozás
  - Nemellenőrzött tanítás, ellenőrzött tanítás
  - K-means, Fuzzy C-means, ...
  - Cimkézett minták alapján: jellemzők kigyűjtése, vagy képrégió egy osztályozni kívánt pont környezetébe
  - ...
  - Jellemzők alapján:
    - Pixel klasszifikáció: *intenzitás* alapon.
    - Pixel klasszifikáció : *intenzitás és hely* alapon
    - ...
  - Szabály alapú osztályozás
    - *szabály-alapú* következtetés: intenzitás és korrelált pozíció.
    - *szabály-alapú* következtetés: intenzitás, entrópia és korrelált pozíció.
    - ...

PCA

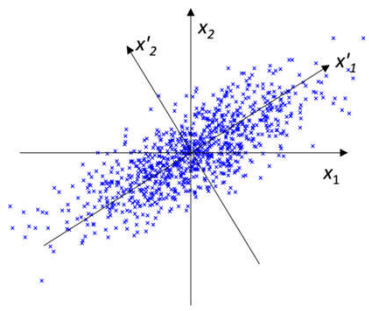

$$\mathbf{y} = \mathbf{T}\mathbf{x}$$

$$\mathbf{T} = \left[\boldsymbol{\varphi}_1, \boldsymbol{\varphi}_2, \ldots, \boldsymbol{\varphi}_N\right]^T$$

$$\boldsymbol{\varphi}_i^T \boldsymbol{\varphi}_j = \delta_{ij}$$

$$\mathbf{T}^T\mathbf{T} = \mathbf{I}, \text{ vagyis } \mathbf{T}^T = \mathbf{T}^{-1}$$

$$\mathbf{x} = \sum_{i=1}^{N} y_i \boldsymbol{\varphi}_i \qquad \hat{\mathbf{x}} = \sum_{i=1}^{M} y_i \boldsymbol{\varphi}_i \qquad M \le N \qquad y_i = \boldsymbol{\varphi}_i^T \mathbf{x}$$

$$\varepsilon^2 = E\left\{\left\|\mathbf{x} - \hat{\mathbf{x}}\right\|^2\right\} = E\left\{\left\|\sum_{i=1}^{N} y_i \boldsymbol{\varphi}_i - \sum_{i=1}^{M} y_i \boldsymbol{\varphi}_i\right\|^2\right\} = \sum_{i=M+1}^{N} E\left\{\left(y_i\right)^2\right\}$$

PCA

$$\varepsilon^2 = \sum_{i=M+1}^{N} E\left\{\left(\boldsymbol{\varphi}_i^T \mathbf{x}\right)\left(\mathbf{x}^T \boldsymbol{\varphi}_i\right)\right\} = \sum_{i=M+1}^{N} \boldsymbol{\varphi}_i^T E\left\{\mathbf{x}\mathbf{x}^T\right\}\boldsymbol{\varphi}_i = \sum_{i=M+1}^{N} \boldsymbol{\varphi}_i^T \mathbf{R}_{\mathbf{xx}} \boldsymbol{\varphi}_i$$

Lagrange multiplikátoros feltételes szélsőérték-keresés

$$\hat{\varepsilon} = \varepsilon^2 - \sum_{i=M+1}^{N} \lambda_i \left(\boldsymbol{\varphi}_i^T \boldsymbol{\varphi}_i - 1\right) = \sum_{i=M+1}^{N} \left[\boldsymbol{\varphi}_i^T \mathbf{C}_{\mathbf{xx}} \boldsymbol{\varphi}_i - \lambda_i \left(\boldsymbol{\varphi}_i^T \boldsymbol{\varphi}_i - 1\right)\right]$$

$$\frac{\partial \hat{\varepsilon}}{\partial \boldsymbol{\varphi}_i} = \sum_{i=M+1}^{N} \left[2\mathbf{C}_{\mathbf{xx}} \boldsymbol{\varphi}_i - 2\lambda_i \boldsymbol{\varphi}_i\right] = \mathbf{0} \qquad \mathbf{C}_{\mathbf{xx}} \boldsymbol{\varphi}_i = \lambda_i \boldsymbol{\varphi}_i$$

$$\varepsilon^2 = \sum_{i=M+1}^{N} \boldsymbol{\varphi}_i^T \mathbf{R}_{\mathbf{xx}} \boldsymbol{\varphi}_i = \sum_{i=M+1}^{N} \boldsymbol{\varphi}_i^T \lambda_i \boldsymbol{\varphi}_i = \sum_{i=M+1}^{N} \lambda_i$$

Tüdőszegmentálás

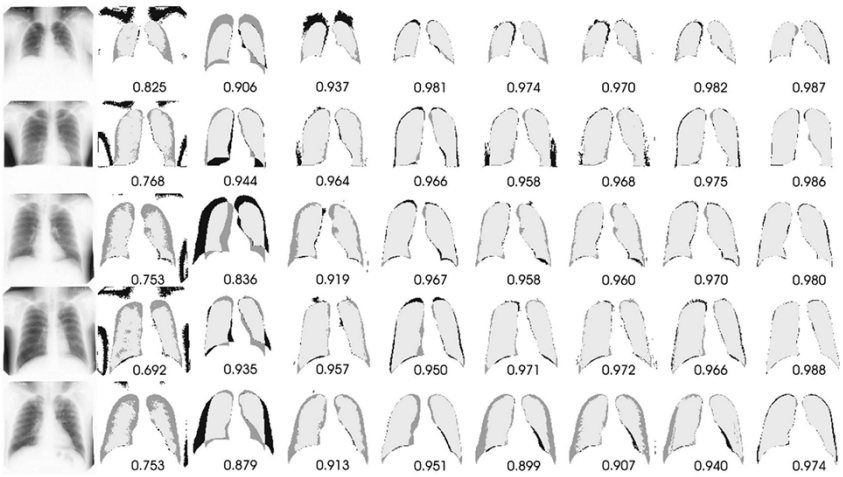

eredeti kép szegmentálás 7 különböző eljárással összehasonlítás

valódi negatív: fehér, valódi pozitív:világos szürke,

false pozitív: sötét szürke, fals negatív: fekete

Tüdőszegmentálás

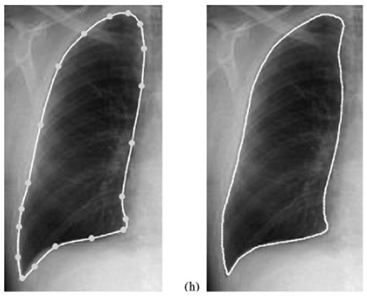

Snake

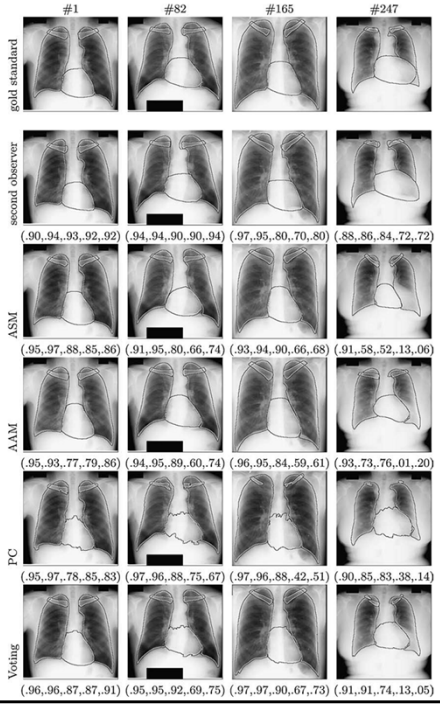

Orvosi képek szegmentálása

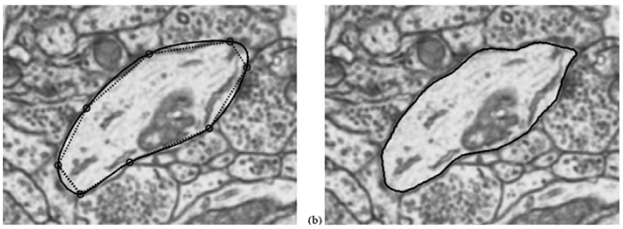

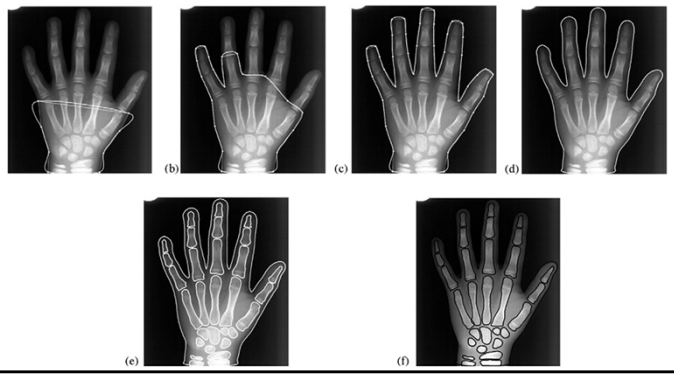

Orvosi képek szegmentálása

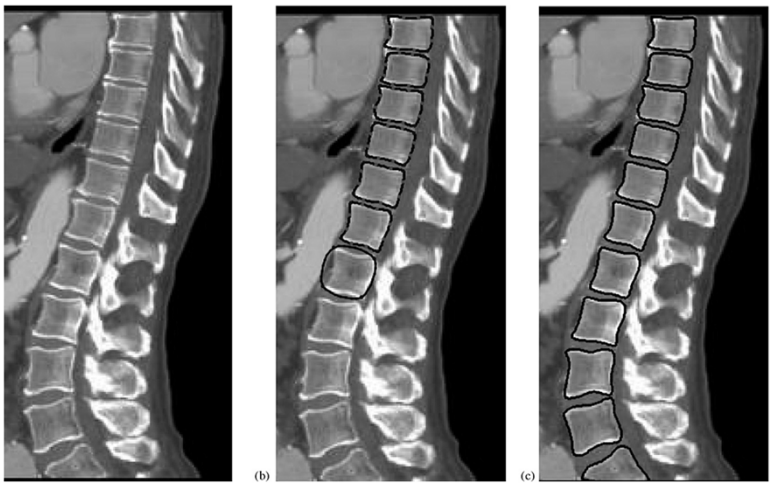

Tüdő-és szív-szegmentálás
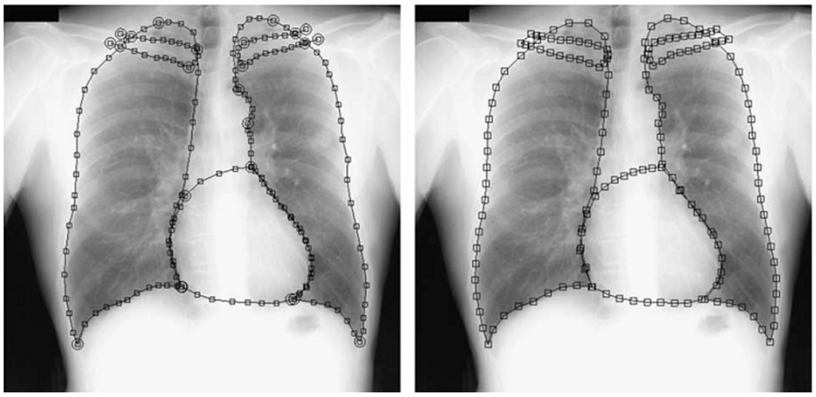
- Deformálható modell (ASM)