

# Deformálható modellek

Orvosi képdiagnosztika

2017. őszi félév

# Deformálható modellek

- A **deformálható modellek** *görbék* vagy *felületek*, melyek különböző hatások eredőjének eredményeképp alakulnak ki.
- Sokféle deformálható (elasztikus) modell
- Elemi alakzatokból összerakhatunk komplex alakzatot.
- A deformálható modellek immunisak a képet terhelő zajokra, a határokon meglévő esetleges kontúrhiányokra, tipikusan numerikus optimalizáció apparátusára támaszkodnak.
- **Két fő csoport**
  - Parametrikus
  - Geometrikus deformálható modellek

# Deformálható modellek

- **Parametrikus modellek**

- A görbe vagy felület leírása tömör, paraméteres formában
- A paraméterek megváltozása a görbe vagy a felület változását eredményezik
- Összeolvasztás, szétvágás topológikus változtatás nem megy
- Energiát minimalizálnak / dinamikus erők mozgatják őket
- Pl. Fourier sor alakmodell, ASM/AAM, ACM

- **Geometriai modellek**

- A modellek a görbe evolúcióján alapulnak,
- Level set módszert alkalmaznak (szint halmazok)
- Többdimenziós skalár függvényként dolgoznak
- Paraméteres formában csak a deformáció után jelennek meg
- Geometriai modellek a topológikus változásokat képesek kezelni

# Geometrikus deformálható modellek

- Görbe evolúció
- Level set módszer
- A görbe evolúció parametrizálástól független mindössze geometriai metrikákat alkalmaz (pl. görbület, normálvektor, de nincs benne paraméter szerinti parciális derivált, stb.)
- A parametrikus eljárásokhoz hasonlóan a képhez kell kötni cél, hogy a görbe a kontúrokhoz konvergáljon

# Fourier sor alakmodell

- $x = x_0 + \sum_{n=1}^{\infty} a_n \sin(n\Theta + \phi_n)$     $y = y_0 + \sum_{n=1}^{\infty} b_n \sin(n\Theta + \psi_n)$ 
  - Az alakot az  $\mathbf{a}$ ,  $\mathbf{b}$ ,  $\psi_n$  és  $\phi_n$  paraméterekkel írjuk le
- Változtatva a paraméterek értékét, és a szummában a tagok számát, különböző alakzatok generálhatók
- Minimalizálási feladat is megfogalmazható, így a paraméteres görbék a képhez igazíthatók (hasonlóan, mint a Snake esetén).
- Szinte tetszőleges alak leírható, anélkül, hogy bármi a priori információnk volna az alakról.
  - De a Fourier reprezentáció nem jó mindenhez – pl. véges sok taggal csak lekerekítve tud sarkokat modellezni
- Adott típusú alakzat tömör modellje is felírható
  - Több képen kiszámítjuk a modell paramétereit
  - Ezekről statisztikát (várható érték, szórás, stb.) készítünk

# ASM/AAM

- Active Shape Models objektumok alakjának statisztikus modelljei, melyeket iteratívan igazítunk egy objektum képi megjelenéséhez
- ASM alapú szegmentálás főbb lépései
  1. Modell kialakításának fázisa:
    - Objektum képeinek kontúrjának jellegzetes pontjainak definiálása (ezek lesznek a landmark /referencia pontok)
    - Landmark pontok gépi / kézi meghatározása
    - Modell kialakítása az objektumot tartalmazó képek alapján
  2. Konkrét képen az objektum szegmentálása:
    - Ismert egy kezdeti becslése a kontúrnak és az ehhez tartozó alakparaméterek
    - Iteratívan modellpontoként normális irányban javítunk, majd a módosult szegmentációt a modellhez illesszük

# ASM/AAM

- Referencia pontok (landmarkok):
  - A szegmentálni kívánt alakot minden képen ezzel a pontkészlettel jellemzünk, melyet géppel / kézzel határozunk meg
  - Fontos, hogy ezek különböző képeken páronként megfeleltethetők legyenek
  - Célszerű jelentéssel bíró / robusztusan és könnyen lokalizálható pontokat keresni (pl. tüdőcsúcs teteje, sarokpontok, stb.)
  - Pontok össze vannak kötve – sorrendjük is fontos
- Modell építése:
  - Referenciapontok átlaga, attól való tipikus eltérésük irányának és mértékének meghatározása




# ASM/AAM

- Egy példa

- Ellenállásokat kell körberajzolni egy áramkör alkatrészrajzán

- Néhány példa a körvonalakra

Referenciapontok és azok összeköttetése





# ASM / AAM

- Az objektumok képi megjelenése általában változó:
  - pozíciójukat
  - orientációjukat
  - méretüket tekintve
- Értelmes modell építéséhez ezt korrigálni kell
  - (Általában) az objektum kontúrjáról akarunk statisztikát nem annak helyéről / orientációjáról / méretéről
  - Általánosan erre szolgál a ponthalmazok regisztrációja
  - Prokrusztész analízis: pozíció, orientáció, méret egyesítés  
Cél: minden referenciapontnak a saját átlagától való négyzetes eltérésének a minimalizálása

# Prokrasztész ágy

**Procrustes**, also called Polypemon, Damastes, or Procoptas, in Greek [legend](#), a robber dwelling somewhere in Attica—in some versions, in the neighbourhood of Eleusis. His father was said to be [Poseidon](#).


**Procrustes had an iron bed** (or, according to some accounts, two beds) on which he compelled his victims to lie.

Here, **if a victim was shorter than the bed, he stretched him by hammering or racking the body to fit.**

Alternatively, **if the victim was longer than the bed, he cut off the legs to make the body fit the bed's length.**


In either event the victim died. Ultimately Procrustes was slain by his own method by the young Attic hero [Theseus](#), who as a young man slayed robbers and monsters whom he encountered while traveling from Trozen to [Athens](#).

The “bed of Procrustes,” or “Procrustean bed,” has become proverbial for arbitrarily—and perhaps ruthlessly—forcing someone or something to fit into an unnatural scheme or pattern.



# ASM/AAM

Prokrusztész analízist követően az egyes pontokra elsozítását mutató PCA



# ASM/AAM

- További példák




# ASM/AAM

Modellépítés jellegzetes helyek  
referenciapontokhoz

A képen jelentéssel rendelkező –  
alkalmazáspecifikus - pontok (pl. szem, orr, stb.)

Alkalmazásfüggetlen jellegzetes pontok  
(Sarokpontok, nagy görbületű tartományok  
pontjai, szélsőértékek, stb.)



# ASM/AAM

- A landmarkok reprezentálása:  $\{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$
- $2n$  dimenziós vektor, ahol  $n$  a landmarkok száma egy képen  
 $\mathbf{x} = (x_1, \dots, x_n, y_1, \dots, y_n)^T$
- Minden képhez meghatározzuk a landmarkokat (kontúr ugyan azon pontjait)
  - Kritikus ezek pontos meghatározása (lokalizációs hibájuk minimalizálása)
- Az alakok ugyanabban a koordinátarendszerben kell megjelenjenek: irány, pozíció, méret egységesítés, úgy hogy az átlagostól való négyzetes eltérés minimumot adjon (Prokrusztész analízis)

$$D = \sum |\mathbf{x}_i - \bar{\mathbf{x}}|^2$$


# ASM/AAM

- Van  $s$  képünk egy  $2n$  dimenziós térben reprezentálva:  $s$  db  $2n$  dimenziós adat (vektor) alkot egy pontfelhőt:
  - A pontok hasonló pozícióban lesznek (regisztráció miatt). A megengedhető alaktartományon belül hasonló, új alakokat is lehet generálni.
  - A sokdimenziós térben a pontok a képek különbözőségei miatt egy közel ellipszoidon belül helyezkednek el. Az ellipszoid középpontját és tengelyeit határozzuk meg.
- Alkalmazzuk a pontfelhőre a PCA-t
- $\mathbf{x} \approx \bar{\mathbf{x}} + \mathbf{P}\mathbf{b}$  közelítő reprezentáció az „eredeti” térben
- $\mathbf{P} = (\mathbf{p}_1 | \mathbf{p}_2 | \dots | \mathbf{p}_t)$  A transzformációs mátrix  $t$  sajátvektorból
- $\mathbf{b} = \mathbf{P}^T(\mathbf{x} - \bar{\mathbf{x}})$  A közelítő reprezentáció a transzformált térben (a sajátvektorok által kifeszített térben)  $\mathbf{b}$  a konkrét alakzatot leíró paramétervektor

# ASM/AAM

- PCA

- 1. átlagképzés  $\bar{\mathbf{x}} = \frac{1}{s} \sum_{i=1}^s \mathbf{x}_i$



- 2. kovariancia mátrix felírása  $\mathbf{S} = \frac{1}{s-1} \sum_{i=1}^s (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^T$

- 3. Határozzuk meg S sajátvektorait  $\mathbf{p}_i$  és sajátértékeit  $\lambda_i$   $i=1, \dots, 2n$

- 4. Rendezzük csökkenő nagyság szerinti sorba  $\lambda_i \geq \lambda_{i+1}$

- 5. Számítsuk ki a jel átlagos négyzetes értékét  $V_T = \sum_i \lambda_i$

- 6. Vegyük az első  $t$  legnagyobb sajátértéket  $\sum_{i=1}^t \lambda_i \geq f_v V_T$   
ahol  $f_v$  adja meg, hogy a teljes variancia

- hány százalékát akarjuk megtartani tipikus érték 80-98 %



# ASM/AAM


- PCA célja a szegmentálandó alakzattípus tömör, paraméteres leírása:
  - Minősít egy konkrét szegmentációt is – konfidencia jelleg
- A modellt igazítani kell a konkrét képhez (szegmentálás célja), ezt numerikus optimalizálással tesszük, pl.  $\min. \|\mathbf{x}(\mathbf{b}) - \mathbf{x}'\|_2^2$ 
  - $\mathbf{x}(\mathbf{b})$  a modell igazított pontjai
  - $\mathbf{x}'$  a szegmentálandó objektum kontúrja
- Tetszőleges eljárás alkalmazható, csak nem ismert  $\mathbf{x}'$ 
  - Persze annyit tudunk, hogy az adott helyen egy kontúrt keresünk, de annak pontos helyét nem ismerjük
  - Ezért inkább:  $\max. G_I \{ \mathbf{x}(\mathbf{b}) \}$   
s.t.  $|\mathbf{b}_{(i)}| \leq 3\sqrt{\lambda_i}$

# ASM/AAM


- $G_I \{ \mathbf{x}(\mathbf{b}) \}$  minősíti, hogy mennyire „jó” kontúr az  $I$  képen az  $\mathbf{x}(\mathbf{b})$  ponthalmaz. Ennek meghatározása feladatfüggő, pl.  $G_I \{ \mathbf{x}(\mathbf{b}) \} = \sum_i |\nabla I(\mathbf{x}(\mathbf{b})_i)|$
- $|\mathbf{b}_{(i)}| \leq 3\sqrt{\lambda_i}$  kényszeríti ki a statisztikához illeszkedés adott mértékét (konfidenciáját)
- Erősen nem konvex jellegű függvények
- Alap eljárás egy iterációja:
  1. A képen minden  $\mathbf{x}(\mathbf{b})_i$ -hez keressük meg legközelebbi él pontjait (lokális maximum a görbe normálisa mentén):  $\mathbf{x}'_i$
  2. Frissítsük  $\mathbf{b}$ -t úgy, hogy  $\mathbf{x}'_i$ -hez legjobban illeszkedjünk:  $\mathbf{b}'_i$
  3. Szóródás korlát alkalmazása:  $\mathbf{b}''_i = \text{sign}(\mathbf{b}'_i) \min \{ |\mathbf{b}'_i|, 3\sqrt{\lambda_i} \}$

# ASM/AAM


- Ha szükséges a regisztráció is (nem csak az alak, hanem annak mérete, lokációja, orientációja is változhat), akkor a Prokrusztész analízis paramétereit is a modell paramétereként kezeljük (szóródás korlátok átírásával / törlésével)




# ASM/AAM



(a)  $b_1 = -3\sqrt{\lambda_1}$



(b)  $b_1 = 0$




(c)  $b_1 = +3\sqrt{\lambda_1}$




(d)  $b_2 = -3\sqrt{\lambda_2}$



(e)  $b_2 = 0$



(f)  $b_2 = +3\sqrt{\lambda_2}$



(g)  $b_3 = -3\sqrt{\lambda_3}$



(h)  $b_3 = 0$




(i)  $b_3 = +3\sqrt{\lambda_3}$

# ASM/AAM

## Multirezolúció

Durvábbtól finomabb felé






Negyed felbontású kép

Fél felbontású kép


Eredeti kép

A profil mentén a mintavételi értékek



# ASM/AAM

Egy jó megoldás



Initial



After 2 iterations



After 6 iterations



After 18 iterations

Egy rossz megoldás



Initial




After 2 iterations




After 20 Iterations

# ASM/AAM

Alkalmazás egy MR képen




Initial



After 1 iteration



After 6 iterations



After 14 iterations

# ASM/AAM

- AAM (Active appearance model)
- Kiindulás: mint az ASM-nél
- Lényeges különbség: AAM minden pixelt felhasznál és ezeket alak és megjelenés szempontból is nézi
- Texturát is figyelembe veszi
- A texturára is készít egy statisztikai modellt:  $\mathbf{t} = \bar{\mathbf{t}} + \Phi_t \mathbf{b}_t$ ,
- Átlagtextura  $\bar{\mathbf{t}}$ , sajátvektorok  $\Phi_t$  textura paraméterek a sajátvektorok terében  $\mathbf{b}_t$
- Az alakot és a texturát együttesen kezeli, ezt is PCA-val

$$\begin{pmatrix} \mathbf{W}_x \Phi_x^T (\mathbf{x} - \bar{\mathbf{x}}) \\ \Phi_t^T (\mathbf{t} - \bar{\mathbf{t}}) \end{pmatrix} = \begin{pmatrix} \mathbf{W}_x \mathbf{b}_x \\ \mathbf{b}_t \end{pmatrix} = \begin{pmatrix} \Phi_{c,x} \\ \Phi_{c,t} \end{pmatrix} \mathbf{c} = \Phi_c \mathbf{c}.$$

$$\mathbf{x} = \bar{\mathbf{x}} + \Phi_x \mathbf{W}_x^{-1} \Phi_{c,x} \mathbf{c}$$

$$\mathbf{t} = \bar{\mathbf{t}} + \Phi_t \Phi_{c,t} \mathbf{c}$$



# ACM Snake

- A szegmentáló kontúr egy paraméteres görbe:
  - $\mathbf{x}(s) = [X(s), Y(s), Z(s)]$ ,  $s \in \mathbb{R}$
- A szegmentáció – energia funkcionál minimalizálása:
  - $E(\mathbf{x}) = E_{\text{int}}(\mathbf{x}) + E_{\text{im}}(\mathbf{x}) + E_{\text{ext}}(\mathbf{x})$
  - Zárt görbe esetén periodicitási kényszer:  $\mathbf{x}(i) \equiv \mathbf{x}(i+k)$   $i \in [0,1]$   $k \in \mathbb{Z}$
- Belső energia ( $E_{\text{int}}(\mathbf{x})$ ):
  - Általában: 
$$E_{\text{int}}(\mathbf{x}) = \frac{1}{2} \int_{s=0}^1 \alpha(s) \cdot \left| \frac{\partial \mathbf{x}}{\partial s} \right|^2 + \beta(s) \cdot \left| \frac{\partial^2 \mathbf{x}}{\partial s^2} \right|^2 ds$$
  - Regularizációként is értelmezhető
  - Első tag kényszeríti ki a szegmentáló görbe folytonosságát
  - Második tag bünteti a görbületet
  - Elfogult – zsugorodásra készíti a görbét  $\rightarrow$  ballon erő kell

# ACM Snake

- Képből származó (külső) energia ( $E_{im}(\mathbf{x})$ ):

- $E_{im}(\mathbf{x}) = \int_{s=0}^1 P(\mathbf{x}(s)) ds$

- $P(\mathbf{x}(s))$  definiálja azt, hogy mit szeretünk

Minden tagban megjelenik egy Gauss függvényes elmosás!

- $P$  tipikus megválasztása:

- Élek:  $-w_{el} \left\| (\nabla G_\sigma * I)(x, y) \right\|_2^2$

$$ang(\mathbf{x}) = \tan^{-1}(\mathbf{x}_{(2)} / \mathbf{x}_{(1)})$$

- Régió:  $w_{reg} \cdot G_\sigma \cdot I(x, y)$

- Vonal szakasz végződése:  $-w_{veg} \cdot \frac{\partial ang(\nabla G_\sigma * I)}{\partial \mathbf{n}(ang(\nabla G_\sigma * I) + \pi)}$

- És még sok egyéb más...

- Cél a súlyok olyan módon történő beállítására, hogy a kontúr az általunk kívánt pontokba kerüljön


$$\mathbf{n}(\mathbf{x})^T \mathbf{x} = 0 \quad \|\mathbf{n}(x)\| = 1$$

# ACM Snake

- Külső energia miatt a célfüggvény nem konvex
  - Hibafelület tele van lokális minimumokkal
  - Részben kezelhető a Gauss kernelekkel történő elmosással
  - És az úgynevezett Gradient Vector Flow „regularizációval”
- Külső energia ( $E_{ext}(\mathbf{x})$ ): felhasználói beavatkozás

(a) Attractive Energy

(b) Repulsive Energy




# ACM Snake szélsőérték keresése

- Tipikus esetben nem konvex a célfüggvény
    - $E(\mathbf{x}) = \int_0^1 P(\mathbf{x}(s)) ds + \frac{\alpha}{2} \int_0^1 \left| \frac{\partial \mathbf{x}(s)}{\partial s} \right|^2 ds + \frac{\beta}{2} \int_0^1 \left| \frac{\partial^2 \mathbf{x}(s)}{\partial s^2} \right|^2 ds$
    - Kép energia miatt zajos, és jelentősen különböző potenciálú (minőségű) lokális szélsőértékek
    - Globális optimum megkeresése NP nehéz
  - Elsőrendű módszerrel optimalizál
    - Gradiens módszer – lassú konvergencia
    - Euler-Lagrange módszer – gyorsabb
      - Gradiens módszer konvergencia pontját keresi közvetlenül
- $$\delta E(\mathbf{x}) = 0 \Leftrightarrow \partial P / \partial \mathbf{x} - \alpha \cdot \mathbf{x}'' + \beta \cdot \mathbf{x}'''' = \mathbf{0}$$


# Lokális optimum probléma

- Lokális optimum probléma:
  - Fontos a kezdeti pozíció megválasztás (2 lépéses eljárások)
  - Kezelése az erőmező regularizációjával (GVF) illetve a képi potenciálok deriválás előtti (multiscale) elmosásával




# Probléma kezelése *multiscale* szűréssel


- Multiscale Gauss bankkal az Energiapotenciál elmosása:



$\sigma = 180$



$\sigma = 10$



# Probléma kezelése *multiscale* szűréssel








- Energiapotenciál elmosása:
  - Nagy szigma: globális optimum „vonzásába” kerül a görbe
  - Kisebb szigma: nem kezeli a lokális optimumok problémáját
  - Lényegében egy regularizáció (szigma  $\sim$  NSR)
- Szükséges-e a globális optimumot megkeresni:
  - Szegmentálások (Snake) esetén tipikusan nem
  - Kétfázisú algoritmusokkal kezelhető a probléma:
    - 1. fázis: közelítően helyes szegmentáció
    - 2. fázis: Snake futtatása az első fázis eredményéből

# GVF regularizáció

- Külső energiát tagot regularizáljuk:
  - Új mezőt definiálunk a külső energiát tag helyett:
$$\mathbf{v}(x, y) = [u(x, y), z(x, y)]$$
  - Melyet az alábbi optimalizációs probléma definiál:
$$\mathbf{v}^* = \arg \min_{\mathbf{v}=[u,z]} \left\{ \iint \mu \cdot \left( \|\nabla u\|_2^2 + \|\nabla z\|_2^2 \right) + \|\nabla P\|_2^2 \cdot \|\mathbf{v} - \nabla P\|_2^2 dx dy \right\}$$
  - Interpretáció:
    - Ahol  $\|\nabla P\|_2^2 \ll \mu$ , ott az integrandus első tagja dominál, a GVF mező sima lesz, így  $\mathbf{v}$  „beáll” a szomszédjai irányába
    - Ahol  $\|\nabla P\|_2^2 \gg \mu$ , ott a regularizáció nem módosít a külső energián
  - $\mathbf{v}$ -t elég egyszer előállítani, nem függ a kontrollpontoktól





# Esettanulmány



# Esettanulmány

- Tumorok szegmentálása mellkas tomoszintézis rétegfelvételen:
  - Input: vizsgálandó elváltozás egy pontja
  - Output: elváltozás körvonala
  - Motiváció: onkológiai kezelés hatásának vizsgálata
- Implementáció kétfázisú eljárással:
  1. Fázis: Elváltozás középpontjának detektálása, elváltozás skálájának becslése – negatív LoG szűrőbank
  2. Fázis: Problémára szabott energiatagokkal Sanke  
Gradiens iránya ellentétes a sugár irányával

# Esettanulmány



Fekete kereszt: input belső pont

Piros kereszt: becsült középpont

Kék görbe: LoG-os kezdeti szegmentáció eredménye

Piros görbe: Snake-el finomított szegmentáció eredménye