


ACTIVE SHAPE MODELS

Metody registrace objektů v obrázku



Václav Krajíček

Oblasti počítačového vidění

- Segmentace

- Registrace

} Active Shape Models

- Klasifikace

Problémy počítačového vidění

- Šum
- Geometrické deformace
- Fotometrické deformace
- Ill-defined
 - Problem regularizace
- Restaurace obrazu

Typy a metody registrace

- Registrace
 - z různých pohledů na objekt
 - z různých modalit
 - v různém čase
 - vzhledem k předloze
- globální/lokální metody
- metody podle typu deformace v obrazku
- statistické metody, metody mapování bodů,
elastické modely

Model

- Matematický popis třídy reálných objektů
 - aproximace
 - pomocí rovnic, vektorů, ...
- Umožňuje
 - Srovnání s realitou
 - Předpověď chování
 - Generovat nové instance
- Parametry

Předchůdci Active Shape Models

- “Klasické” metody
 - Registrace 'tuhých' objektů
 - Citlivé na šum, globalní charakter
- Metody založené na elastických modelech
 - Na míru konkrétní aplikaci, nebo příliš obecné
- Snakes – 1987 Kass et al.

Snakes: Active Contour Models

- Silná nízkorúrovňová metoda registrace kontur
- Princip minimalizace energie
 - Metody numerické matematiky
- Počítá se zásahem z vyšší vrstvy
 - Uživatel
 - Jiný algoritmus, software
- Snake Pit
- ...

Ukázka: Tracking Video



Jak hadi pracují...

- Křivky – uzavřené i otevřené
 - Spline – vnitřní síly, Vnější podmínky – vnější síly
- Kroky:
 - 1) Iniciální poloha křivky
 - Důležitá
 - Vnější zásah, heuristiky, náhodný pokus
 - 2) Minimalizace energie systému
 - Určení energetických funkcionalů
 - Řešení diferencíálních rovnic – Eulerova metoda

Minimalizace energie hadů

$$E_{snake}^* = \int_0^1 E_{snake}(v(s)) ds$$

$$= \int_0^1 E_{int}(v(s)) + E_{image}(v(s)) + E_{con}(v(s)) ds$$


$$(E_{snake}^*)' = 0$$

Vnitřní & Vnější energie

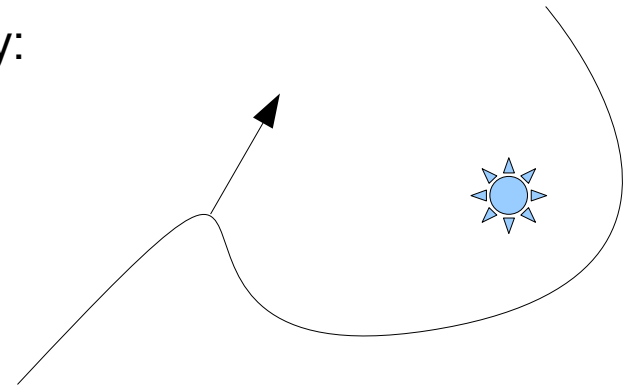
$$E_{int} = (\alpha(s)|v_s(s)|^2 + \beta(s)|v_{ss}(s)|^2)/2$$

$$E_{int}(i) = \alpha_i |v_i - v_{i-1}|^2 / 2h^2 + \beta_i |v_{i-1} - 2v_i + v_{i+1}|^2 / 2h^4$$

$\beta=0$:



Vnější podmínky:



$$E_{ext} = E_{image} + E_{con}$$

Ukázka: Tracking + Ext. Síly

Aproximace

$$E_{snake}^* = \sum_{i=0}^n E_{int}(i) + E_{ext}(i)$$

$$E_{int} \left\{ \begin{aligned} &\alpha_i (v_i - v_{i-1}) - \alpha_{i+1} (v_{i+1} - v_i) \\ &+ \beta_{i-1} [v_{i-2} - 2v_{i-1} + v_i] \\ &- 2\beta_i [v_{i-1} - 2v_i + v_{i+1}] \\ &+ \beta_{i+1} [v_i - 2v_{i+1} + v_{i+2}] \\ &+ (f_x(i), f_y(i)) = 0 \end{aligned} \right.$$

E_{ext}

→ Maticový tvar

→ Explicitní
Eulerova metoda

→ Nalezení
inverzní matice

Výpočet

- Maticový tvar

$$Ax + f_x(x, y) = 0$$



$$Ay + f_y(x, y) = 0$$

- Eulerova metoda

$$Ax_t + f_x(x_{t-1}, y_{t-1}) = -\gamma(x_t - x_{t-1})$$

$$Ay_t + f_y(x_{t-1}, y_{t-1}) = -\gamma(y_t - y_{t-1})$$

Ukázka





Active Shape – 'Smart Snakes'

- 1992 – Cootes et al.
- Registrace 'měkkých' tvarů
- Modely založené na statistické analýze výskytu reálných objektů
 - Využívá externí znalosti
 - Transformace na parametry modelu

Point Distribution Model

- Reprezentace objektu pomocí očíslovaných (labeled) bodů
 - Nejčasteji na hranici, význačná místa - rohy
 - Vnitřní struktura, okolí
- Trénovací množina třídy objektů
 - Body na všech členech množiny si **musí odpovídat**
 - Časově náročné, manuální
 - Obsahuje odbornou znalost

Příklad: Labelování rezistorů



Zarovnání trénovací množiny

- Nezáleží na poloze, orientaci a velikosti objektu v trénovacích datech
- Vytváříme model tvaru \Rightarrow Tvar je důležitý
- Otočíme, posuneme, naškálujeme každý prvek trénovací množiny \Rightarrow minimalizujeme vážený součet vzdáleností odpovídajících bodů ze všech objektů trénovací množiny

Zarovnání dvou tvarů

- Vektor popisující tvar i

$$\mathbf{x}_i = (x_{i0}, y_{i0}, x_{i0}, y_{i0}, \dots, x_{ik}, y_{ik}, \dots, x_{in-1}, y_{in-1})$$

- Pro dva tvary i a j

$$E_j = (\mathbf{x}_i - M_j(\mathbf{x}_j))^T \mathbf{W} (\mathbf{x}_i - M_j(\mathbf{x}_j))$$

- Váhy \mathbf{W} postihují stabilitu bodů napříč trénovací množinou

$$w_k = \left(\sum_{I=0}^{n-1} V_{R_{kl}} \right)^{-1}$$

Zarovnání dvou tvarů

- Matice M_j provádí 'tuhé' transformace

$$M_j \begin{pmatrix} x_{jk} \\ y_{jk} \end{pmatrix} = \begin{pmatrix} (s_j \cos \theta) x_{jk} - (s_j \sin \theta) y_{jk} + t_{jx} \\ (s_j \sin \theta) x_{jk} + (s_j \cos \theta) y_{jk} + t_{jy} \end{pmatrix}$$

- Snadno vyřeší při substituci

$$a_x = s \cos \theta$$

$$a_y = s \sin \theta$$

Algoritmus zarovnání celé množiny

- 1) Zarovnej každý s prvním
- 2) Opakuj dokud nezkonverguje
 - 1) Spočítej *průměr* ze všech tvarů
 - 2) Normalizace - **důležitá**
 - a) Přepočti *průměr* na standartní rozměry, směr a polohu
 - b) Zarovnej *průměr* na první tvar
 - 3) Zarovnej všechny tvary na *průměr*

Trénovací množina \Rightarrow Model

- Průměr a odchylky od *průměru*

$$\bar{x} = \frac{1}{N_s} \sum_{i=1}^{N_s} x_i \quad dx_i = x_i - \bar{x}$$

- Kovarianční matice odchylek

$$S = \frac{1}{N_s} \sum_{i=1}^{N_s} dx_i dx_i^T$$

PCT

- Karhunen-Loèveho transformace
- Provedeme PCT na odchylky tvarů od průměru
- Výsledek PCT
 - Vlastní vektory – složky korelované informace, tzv. **módy variace**
 - Vlastní čísla – poměr zastoupení informace příslušném vektoru

$$Sp_i = \lambda_i p_i$$
$$\lambda_i \geq \lambda_{i+1}, p_i^T p_i = 1$$

Model

- Kolik módů variace použiju $\Rightarrow t$ stupňů volnosti

$$\lambda_T = \sum_{i=1}^{2n} \lambda_i$$

- **Hlavní trik**

$$x = \bar{x} + Pb \quad P = (p_1 p_2 \dots p_t)$$
$$b = (b_1 b_2 \dots b_t)^T$$

- Výpočet b

protože platí $P^T P = I$, pak $b = P^T (x - \bar{x})$

Příklad






Figure 4 : Plot of b_1 vs b_2 for a training set of resistor shapes.




-0.9 ← b_1 → 0.9

Figure 5 : Effects of varying the first parameter of the resistor model.



-0.3 ← b_2 → 0.3

Figure 6 : Effects of varying the second parameter of the resistor model.



-0.25 ← b_3 → 0.25

Figure 7 : Effects of varying the third parameter of the resistor model.

Příklad

| Eigenvalue | λ_i | $\frac{\lambda_i}{\lambda_T} \times 100\%$ | $\sqrt{\lambda_i}$ |
|-------------|-------------|--|--------------------|
| λ_1 | 0.207 | 66% | 0.46 |
| λ_2 | 0.026 | 8% | 0.16 |
| λ_3 | 0.017 | 5% | 0.13 |
| λ_4 | 0.013 | 4% | 0.11 |
| λ_5 | 0.010 | 3% | 0.10 |
| λ_6 | 0.008 | 3% | 0.09 |

Příklad




Figure 8 : Training set of hand shapes, each defined by 72 points.




Figure 9 : Effects of varying each of the first three parameters of the hand model individually.

Další krok

- Zkombinovat Snakes a náš model
 - Snakes jsou řízeni pouze jednoduchými vnějšími podmínkami – vnější síly
 - Nahradíme vnější síly naším modelem
 - Lokální optimalizace
 - Vyhneme se použití vnitřních sil
 - Hledání *vlastností* v obrázku zůstává
- Získáme lokalizátor objektů vedený modelem naučeným z reálných dat
 - Dokáže se lépe vyrovnat s chybami v obraze

Algoritmus registrace

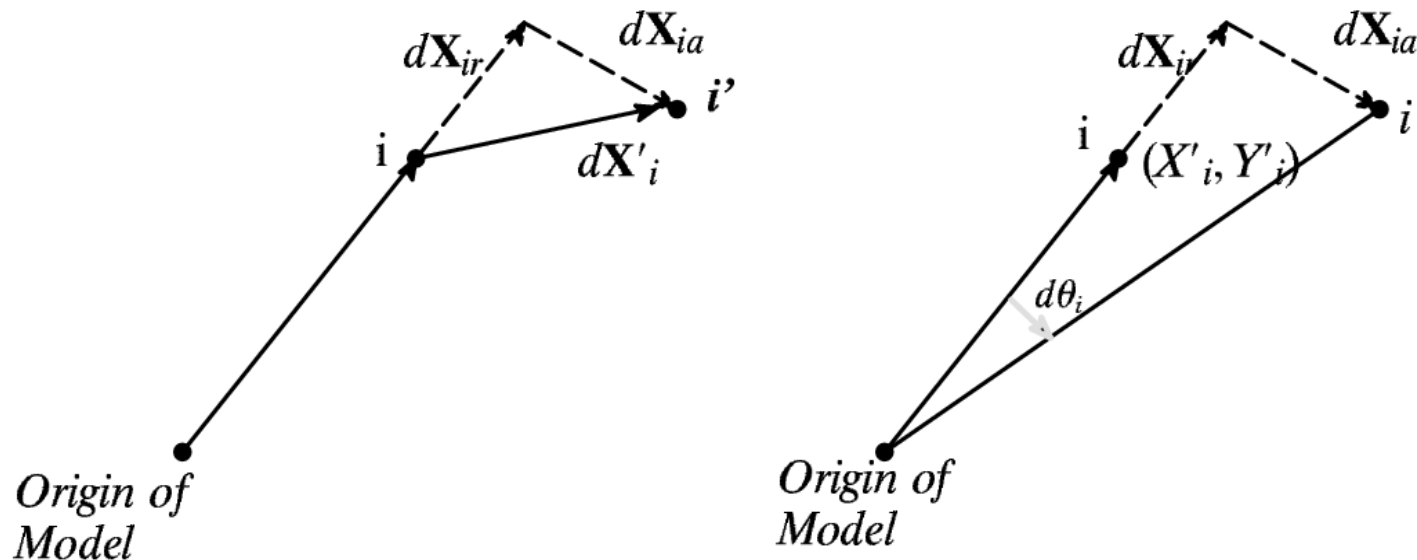
- 1) Počáteční odhad polohy modelu a bodů v obraze
- 2) Opakuj dokud nezkonverguje
 - a) Nalezni “lepší” pozice pro body
 - b) Přepočítej posunutí, orientaci a zvětšení modelu
 - c) Spočítej změněné parametry modelu
 - d) Spočítej novou polohu bodů v rámci parametrů modelu

Nalezení lepší pozice pro body

- Mnoha způsoby
 - Body model si sebou mohou nést další informace
- Prohledávání obrázku
 - Detekce hran
 - Na normále k hranici modelu, podle tloušťky hrany
 - Využití šedotonového spektra v okolí
 - Ruzné typy okolí

Přepočet polohy modelu

- Hledáme (dX_c, dY_c) , $(1+ds)$ a $d\theta$, aby součet vzdáleností bodů takto modifikového modelu a nalezených “lepších” pozic byl nejmenší
- Lze přesně, ale aproximace stačí



Výpočet nových parametrů modelu

- Hledám rezidua nových poloh bodů modelu a “lepší” poloh pro body v lokálním systému souřadnic modelu

$$M(s(1 + ds), \theta + d\theta)[\mathbf{x} + d\mathbf{x}] + (X_c + dX_c) = (X + dX)$$

$$d\mathbf{x} = M((s(1 + ds))^{-1}, -(\theta + d\theta))[M(s, \theta)[\mathbf{x}] + dX - dX_c] - \mathbf{x}$$

- Nové pozice bodů nemusí být v limitu modelu!

$$\mathbf{x} + d\mathbf{x} \approx \bar{\mathbf{x}} + P(\mathbf{b} + d\mathbf{b})$$

Výpočet nových parametrů modelu

- Odečteme model od předchozí aproximace


$$d \mathbf{x} \approx P (d \mathbf{b})$$

$$d \mathbf{b} = P^T d \mathbf{x}$$

- Kontrola a zabránění překročení limitů parametrů modelu

$$D_m^2 = \sum_{i=1}^t \left(\frac{b_i^2}{\lambda_i} \right) \leq D_{max} \quad b_i \rightarrow b_i \cdot \frac{D_{max}}{D_m} (i=1..t)$$

Ukázka: Rezistory




(a) Original Image




(b) Initial Position




(c) After 30 iterations



(d) After 60 iterations




(e) After 90 iterations




(f) After 120 iterations


Ukázka: Ruka




(a) Initial Position



(b) 100 iterations



(c) 200 iterations



(d) 350 iterations

Vyhledávání podle úrovně šedé

- Vylepšení postupu pro nalezení “lepších” pozic
- Spočítám průměrné okolí bodů v trénovací množině
 - Okolí libovolného tvaru
 - Pro jednoduchost usečka ve směru normály k hranici \Rightarrow profil

$$g_{ijk} = I_j(\mathbf{y}_{i(k+1)}) - I_j(\mathbf{y}_{i(k-1)})$$

Vyhledávání podle úrovně šedé

- Normalizace + derivace \Rightarrow invariance k přičtení a vynásobení konstantou

$$g_{ij}' = \frac{g_{ij}}{\sum_{k=1}^{n_p} |g_{ijk}'|}$$

$$\bar{g}_i = \frac{1}{N_s} \sum_{j=1}^{N_s} g_{ij}'$$

- Vyhledávání \Rightarrow minimalizace Mahalanobisovy vzdálenosti

$$f_{prof} = (\mathbf{h}(d) - \bar{\mathbf{g}})^T S_g^{-1} (\mathbf{h}(d) - \bar{\mathbf{g}})$$

Genetické algoritmy

- Řešení vyhledávacího problému
- Iterativní proces nad množinou možných řešení
- Výběr nejlepších kandidátů pro další “generaci”
 - Fitness funkce
 - Mutace, křížení
- Pro naši ulohu jedinec reprezentuje polohu a parametry modelu
- Úspěšně použito \Rightarrow rychlejší vyhledávání



Genetické algoritmy

- Dva způsoby začlenění GA
 - 1) Předzpracování – nalezení startovní pozice pro ASM
 - 2) Začlenění ASM do GA – hledat optimum přímo pomocí GA


Příklad: Lékařské aplikace

- Většina organů v těle je deformovatelná,
- Exempláře se tvarem mohou podstatně lišit
- Přesto základní struktura a topologie je stejná
- Úloha registrace orgánů
 - MR, CT
- Úloha trackování orgánů na záznamu
 - Ultrazvuk – Echokardiogram
- CAS
- Existuje mnoho trénovacích dat


Ukázka: Echokardiogram




Ukázka: Echokardiogram



Ukázka: Echokradiogram



(a) Initial State







(b) After 20 iterations







(c) After 50 iterations

Ukázka: Echokradiogram - tracking




Ukázka: MR - řezy mozkiem



Rozšíření do 3D

1) 2D verze na řezy a pak spojit odpovídající body v sousedních řezech

- Zavádí se systematická chyba

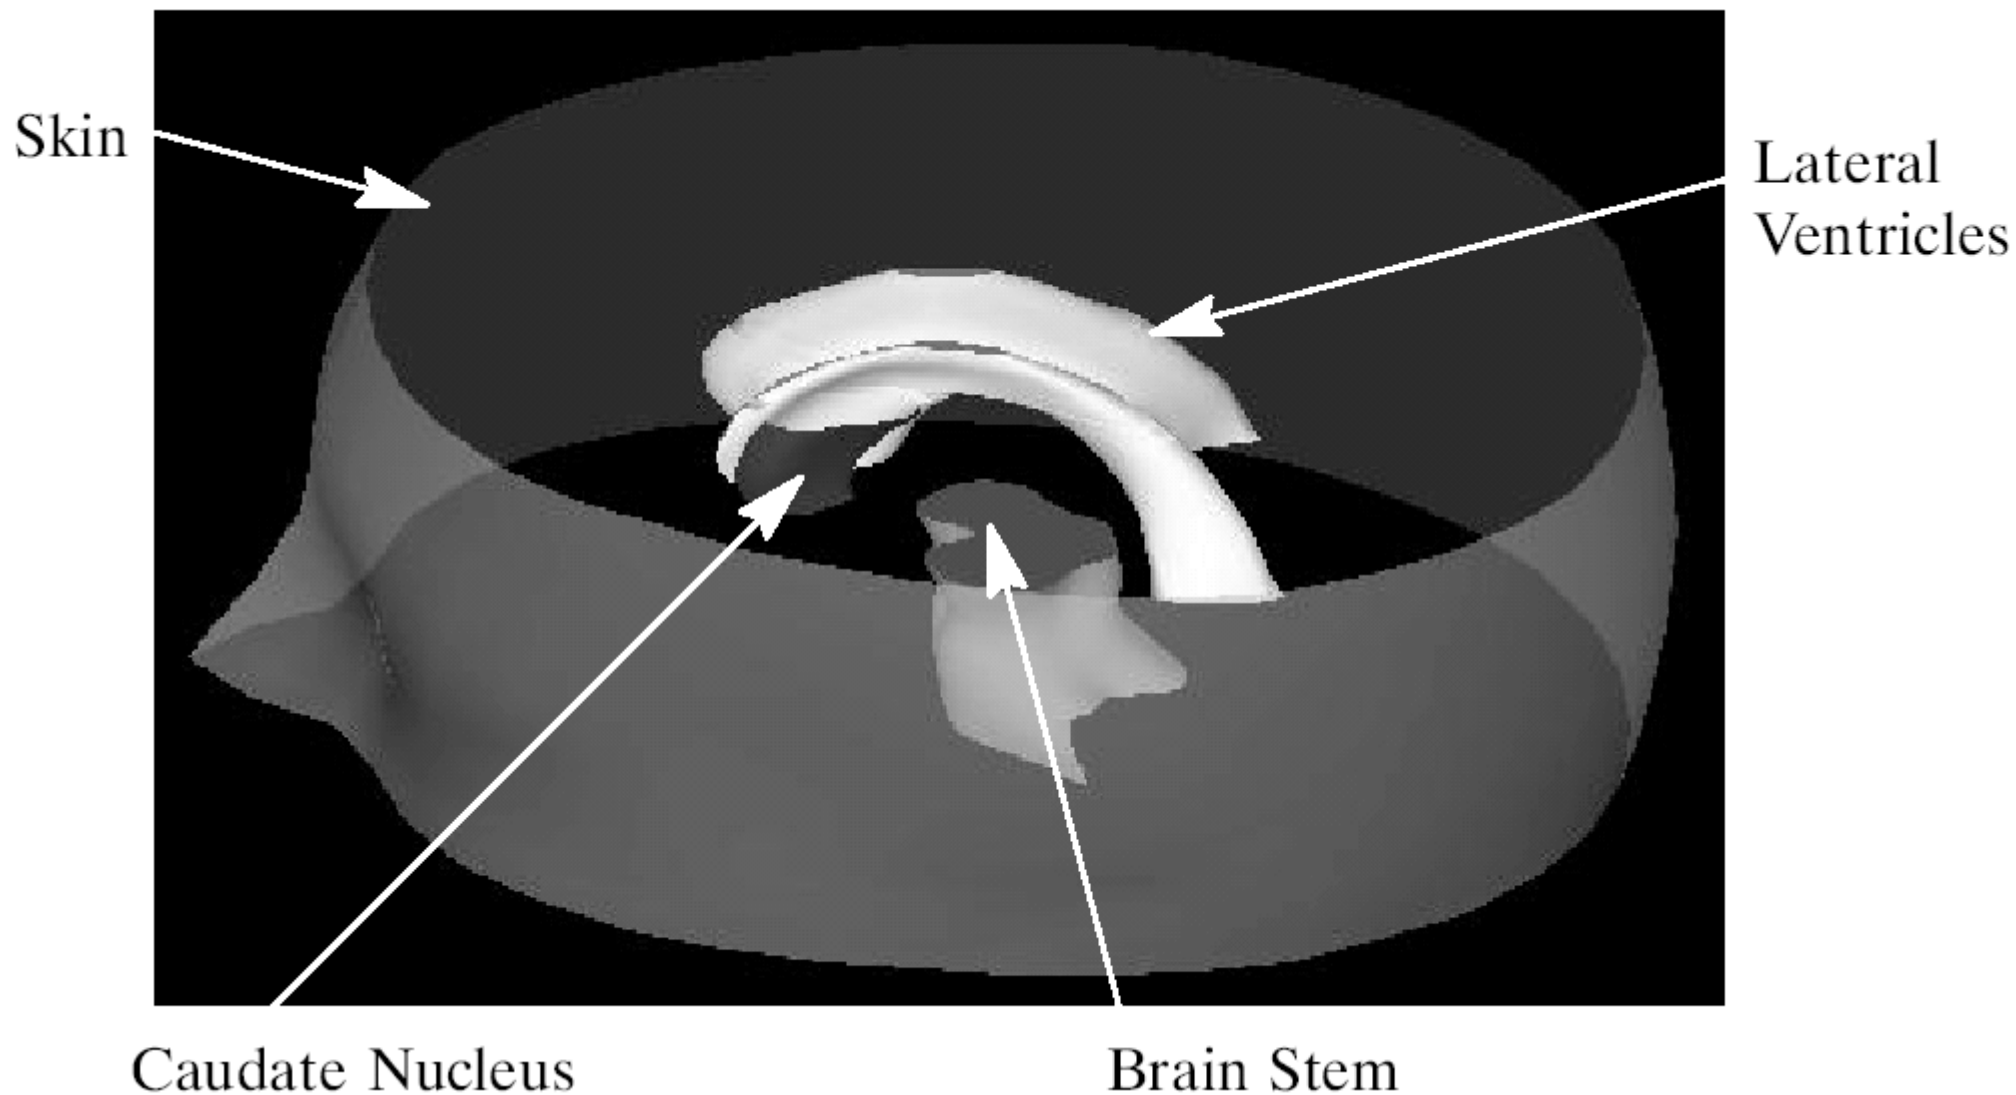


Rozšíření do 3D

2) Plný 3D PDM




- Náročné vytvoření trénovací množiny
- Interaktivní software pro tvorbu PDM
- Náročnější na výpočet, více dat
 - 2000+ bodů na model, 20-30 modů variace
 - 30 sec ASM + 10 min GA na SUNsparc10 (1993)
 - Člověku trvá segmentace v rádech hodin

Ukázka: Model mozku






Ukázka: Módy variace 3D PDM

b_1



b_2



Závěr

- Pohled na objekty přes minima jistých funkcionalů
- Tvorba modelů
- Hledání objektů v datech pomocí modelů
 - Přímým výpočtem – numerické metody
 - Iteračním prohledáváním – lokální optimalizace
 - Genetickými algoritmy
- Ukázky a příklady

Reference

- M.Kass A.Witkin and D.Terzopoulos – Snakes: Active Contour Models
- Training Models of Shape from Sets of Examples – T.F.Cootes, C.J.Taylor, D.H.Cooper, J.Graham
- Active Shape Models – 'Smart Snakes' – T.F.Cootes, C.J.Taylor
- Use of Image Shape Models For Locating in Medical Images – T.F.Cootes, A.Hill, C.J.Taylor and J.Haslam
- Model-Based Interpretation of 3D Medical Images – A.Hill, A.Thorman an C.J.Taylor
- <http://www.robots.ox.ac.uk/~contours/>
- <http://julien.jomier.com/courses/comp258/lecture-snakes/main.htm>

