



Segmentácie obrazu

Šonka, Hlaváč, Boyle: Image processing, Analysis and Machine Vision
kapitola: Segmentation

Richard Szeliski: Computer Vision: Algorithms and Applications
kapitola: Segmentation

Segmentácia obrazu

- Hlavným cieľom segmentácie je rozdeliť obraz na časti, ktoré majú silnú koreláciu s objektmi alebo oblasťami reálneho sveta zobrazenými v obraze.




Úplná vs. čiastočná segmentácia

- Pri čiastočnej segmentácii je cieľom rozdeliť obraz na časti, ktoré sú homogénne z hľadiska vybranej vlastnosti, napr. jasú, farby, odrazivosti, textúry apod.



Úplná vs. čiastočná segmentácia

- Úplná segmentácia - rozdelenie obrazu na disjunktné oblasti, ktoré zodpovedajú objektom reálneho sveta



- Každá oblasť môže byť reprezentovaná uzavretou hranicou a každá uzavretá hranica popisuje oblasť.
- Nejednoznačnosť obrazových dát je hlavným segmentačným problémom, často sprevádzaným informačným šumom.
- Čím viac apriórnej informácie je k dispozícii pri segmentačnom procese, tým lepšie výsledky pri segmentácii možno dosiahnuť.

- Segmentácia môže byť na základe
 - úrovni šedej,
 - farby,
 - textúry,
 - hĺbky alebo
 - pohybu.



Segmentácia na základe úrovni šedej

- Jednoduchá metóda môže viesť k nepresnostiam v segmentácii





Segmentácia na základe textúry

- Umožňuje segmentovať povrchy objektov z rôznou textúrou



Segmentácia na základe pohybu


- Je potrebný medzikrok – vypočítať *optical flow field*




Segmentácia na základe hĺbky

- Užitočné pri mobilných robotoch

Original
image



Range
image



Segmented
image




Image segmentation

Potrebujeme definovať a implementovať kritéria podobnosti








- Čo chceme aby bolo v každom regióne podobné?
- Existuje nejaká vlastnosť, ktorá spôsobí, že región bude zmysluplný objekt ?

Gestalt laws

A series of factors affect whether elements should be grouped together.

- Proximity: tokens that are nearby tend to be grouped.
- Similarity: similar tokens tend to be grouped together.
- Common fate: tokens that have coherent motion tend to be grouped together.
- Common region: tokens that lie inside the same closed region tend to be grouped together.
- Parallelism: parallel curves or tokens tend to be grouped together.

Gestalt laws

	Not grouped
	Proximity
	Similarity
	Similarity
	Common Fate
	Common Region
	


Gestalt laws

- Closure: tokens or curves that tend to lead to closed curves tend to be grouped together.
- Symmetry: curves that lead to symmetric groups are grouped together.
- Continuity: tokens that lead to “continuous” curves tend to be grouped.
- Familiar configuration: tokens that, when grouped, lead to a familiar object, tend to be grouped together.


Gestalt laws




Parallelism



Symmetry



Continuity



Closure

Segmentačné kritéria

- Segmentácia je rozdelenie obrazu I na množinu regiónov S_i , ktoré spĺňajú nasledujúce kritéria :

1. $\cup S_i = S$

Rozdelenie pokrýva celý obraz

2. $S_i \cap S_j = \emptyset, i \neq j$

Žiadne regióny sa neprekrývajú

3. $\forall S_i, P(S_i) = \text{true}$

Homogenita je splnená pre každý región

4. $P(S_i \cup S_j) = \text{false},$
 $i \neq j, S_i \text{ adjacent } S_j$

Zjednotenie susedných regiónov nespĺňa kritéria.

Segmentačné metódy

Pixel-based

- Histogram
- Clustering

Edge-based

Region-based

- Region growing
- Split and merge

Model-based

Physics-based

Graph-based

Thresholding, modifications

Local adaptive thresholds, rozdelí obraz na podobrazy a určí threshold pre každý z nich

Band thresholding, nech D je množina intenzít

$$g(i, j) = \begin{cases} 1 & \text{for } f(i, j) \in D, \\ 0 & \text{otherwise.} \end{cases}$$

Multiple thresholds.

Semi-thresholding, potláča pozadie, užitočné ak obraz je analyzovaný človekom


$$g(i, j) = \begin{cases} f(i, j) & \text{for } f(i, j) \geq \text{Threshold,} \\ 0 & \text{for } f(i, j) < \text{Threshold.} \end{cases}$$

Automatický threshold

p -tile thresholding, ak vieme že objekt pokrýva $1/p$ obrazu

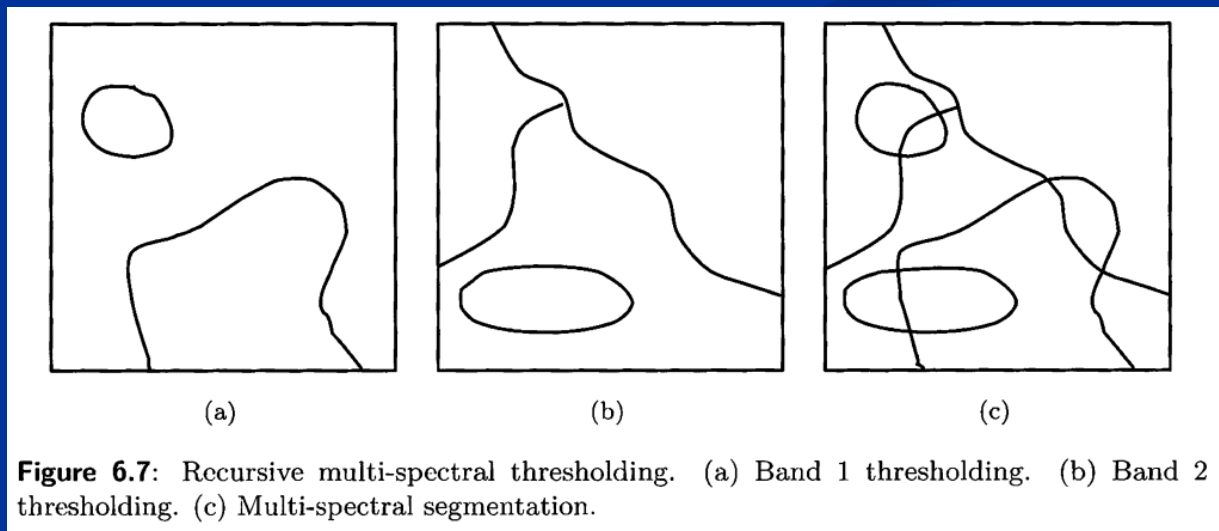
Tlačené znaky na papieri => $1/p$ histogramu

Analýza tvaru histogramu, rôzne objekty na pozadí zodpovedajú bi-modalnemu histogramu. Nájdi stredy medzi módmí




Multispektrálne prahovanie

- Multispektrálne kombinuje prahovanie z viacerých zložiek
 - Farebný obraz
 - Remote sensing
 - Meteorologické satelitné obrázky



■ Segmentácia leteckej snímky



Hierarchické prahovanie

- Hierarchické kombinuje prahovanie z viacerých úrovní




Figure 5.8: *Hierarchical thresholding: (a) pyramid level n , segmentation to objects and background; (b) pyramid level $n - 1$, showing where the thresholding must be repeated for better precision.*

Segmentácia založená na hranách

- Nájdem hrany (lokálne) potom ich pospájam a vytváram oblasti
 - Sledovanie hranice

Sledovanie hranice

- Ak nie je známa hranica, ale v obraze sú známe oblasti, môžeme detegovať hranicu. Poznáme tri typy hranice oblasti:
 - vnútornú,
 - vonkajšiu a
 - rozšírenú.
- Vnútorná hranica je vždy časťou oblasti, ale vonkajšia nikdy nie. Preto dve susedné oblasti nemajú spoločnú hranicu, či použijeme vnútornú hranicu alebo vonkajšiu.

Rozšírená hranica je definovaná ako jednoduchá spoločná hranica medzi dvoma susednými oblast'ami, ktorá je špecifikovaná súradnicami obrazových bodov. Má lepšie vlastnosti ako vnútorná alebo vonkajšia hranica.

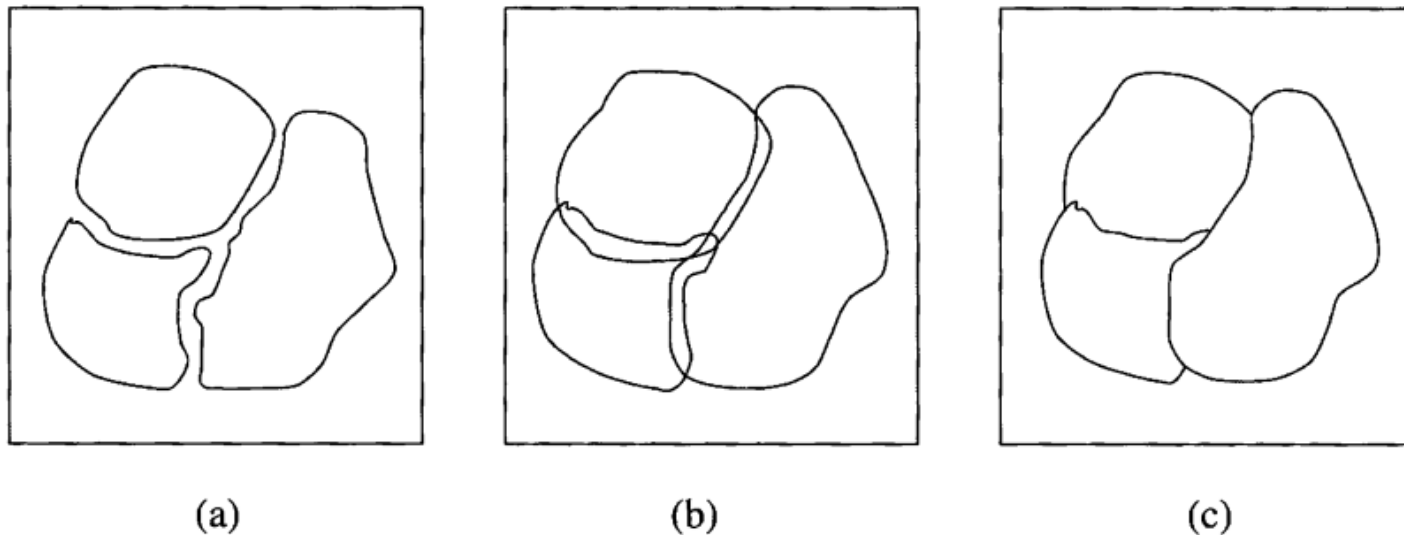
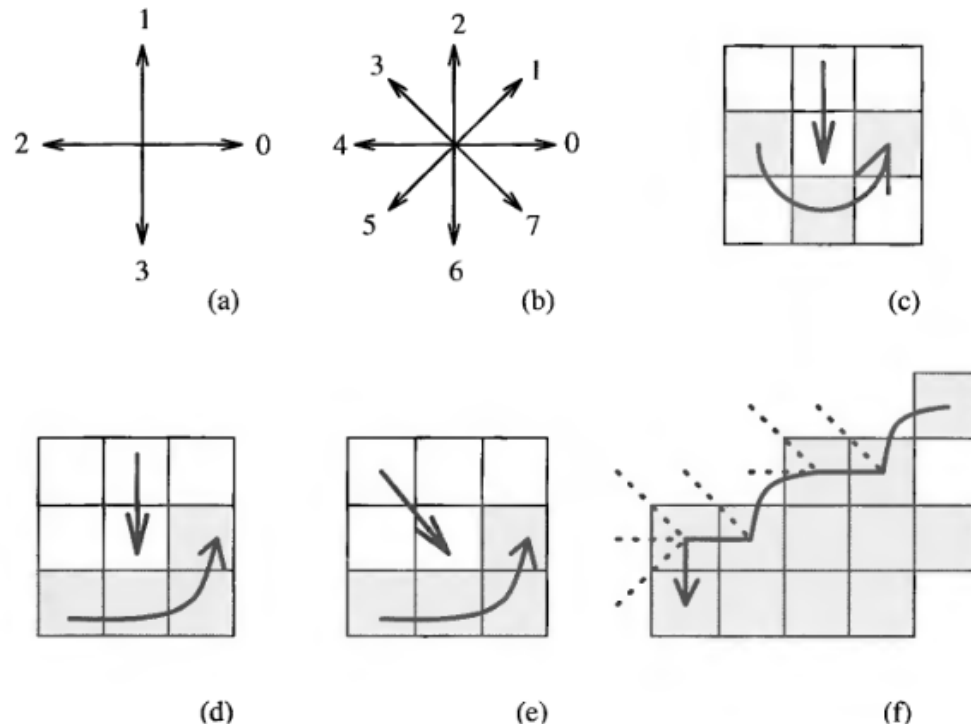


Figure 6.16: Boundary locations for inner, outer, and extended boundary definition. (a) Inner. (b) Outer. (c) Extended.

Sledovanie vnútornej hranice



nájdeme najvrchnejší,
najľavejší obrazový
bod objektu,

a hľadáme ďalšie body hranice buď v 4. susednosti alebo
v 8-susednosti - treba osobitne uvažovať o sledovaní dier.

sledovanie vonkajšej hranice

- niektoré pixle môžu byť súčasťou vonkajšej hranice viackrát.


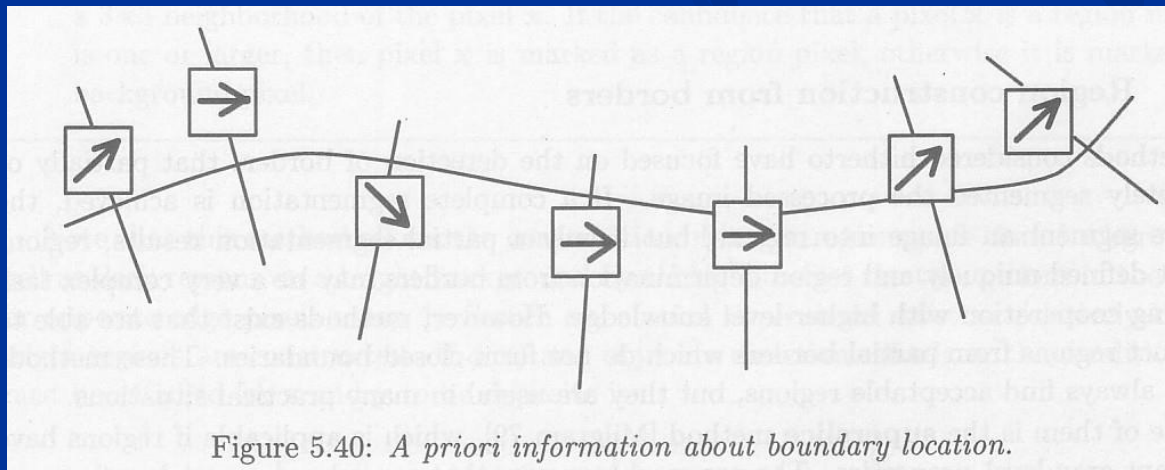


Figure 6.15: Outer boundary tracing; • denotes outer border elements. Note that some pixels may be listed several times.

- sledovať hranicu je možné aj v **šedo-úrovňových obrazoch**, kde zatiaľ neboli identifikované oblasti – potom je hranica reprezentovaná jednoduchou cestou obrazových bodov s **vysokým gradientom** v obraze.

Určovanie hranice s využitím informácie o umiestnení hranice

- využíva apriórnu informáciu.
- Tá sa môže získať z nejakej znalosti vyššieho stupňa alebo zo segmentácie na nižšej úrovni rozlíšenia.
- **Jedna možnosť** je určiť hranicu ako umiestnenie významných lokálnych hrán, ktorú sú blízko k predpokladanej hranici. Nové body hranice sú hľadané v smere kolmom na predpokladanú hranicu.



- **Druhá možnosť'** je založená na apriórnej znalosti koncových bodov, predpokladá sa nízka úroveň šumu a relatívne rovná hranica. Spojnica medzi koncovými bodmi sa iteratívne delí a hľadá sa najsilnejšia hrana umiestnená v smere kolmom na spojnicu medzi dvoma bodmi delenia. Tento proces iteratívne zjemňuje priebeh hranice.




Figure 5.41: *Divide-and-conquer iterative border detection; numbers show the sequence of division steps.*

Určovanie oblasti na základe hranice

- Ak je známa úplná segmentácia - táto úloha je jednoduchá.
- Ak je známa iba čiastočná segmentácia - netriviálne, pretože máme iba časti hranice, ktorá nevytvára uzavretú krivku.

Určovanie oblasti na základe hranice

- Jedna z metód prahuje dáta z čiastočnej segmentácie s rôznym prahom. Tie oblasti, ktoré sa najlepšie zhodujú s čiastočnými známymi hranicami, sú akceptované ako správne.
- Iná možnosť je využiť pravdepodobnosť toho, že obrazový bod sa nachádza vo vnútri uzavretej oblasti ohraničenej čiastočnou známou hranicou. Body hranice sa popisujú ich polohou a smerom lokálnej hrany. Hľadá sa protiľahlý pixel hrany.





Figure 5.42: *Region forming from partial borders: (a) original image; (b) thresholding; (c) edge image; (d) regions formed from partial borders.*

Simultánne hľadanie hranice

- Je založené na pozorovaní, že informácia, obsiahnutá v polohe jednej hranice môže byť užitočná pre identifikáciu polohy druhej hranice.
- Ak sa definuje ohodnocovacia funkcia, ktorá kombinuje cenu hrany z ľavej a pravej časti hranice, potom je možné použiť na optimálnu detekciu hranice buď heuristické hľadanie v grafe alebo metódy dynamického programovania.

Watershed - segmentácia s využitím povodí



- Pri tejto metóde reprezentujú oblasti segmentovaného obrazu zberné nádrže, a reprezentujú lokálne minimum.





Figure 5.49: One-dimensional example of watershed segmentation: (a) gray-level profile of image data; (b) watershed segmentation—local minima of gray-level (altitude) yield catchment basins, local maxima define the watershed lines.

Watershed - segmentácia s využitím povodí

- Hranice oblastí sú tvorené bodmi, kde sa úroveň jasnosti menia najrýchlejšie
- Používame Gradientný obraz



Dva prístupy pre watershed

- Prvý prístup cez watershed segmentáciu spočíva v nájdení cesty vedúcej od daného pixla smerom dolu k lokálnemu minimu v zbernej nádrži. Tu sa pixle usporiadajú podľa toho, v ktorom minime sa skončí ich cesta.
- Pri druhom prístupe každé minimum šedej úrovne reprezentuje jednu zbernú nádrž a stratégia spočíva v plnení týchto nádrží smerom nahor.







Figure 5.50: Geodesic influence zones of catchment basins.




Výpočtová zložitosť

- Sortovanie $O(n \log n)$
- Watershed $O(n)$
 - Obraz obvykle 256 úrovní šedej \Rightarrow bin sort $O(n)$




(a)



(b)



(c)




(d)

Figure 5.51: *Watershed segmentation: (a) original; (b) gradient image, 3×3 Sobel edge detection, histogram equalized; (c) raw watershed segmentation; (d) watershed segmentation using region markers to control over-segmentation. Courtesy W. Higgins, Penn State University.*

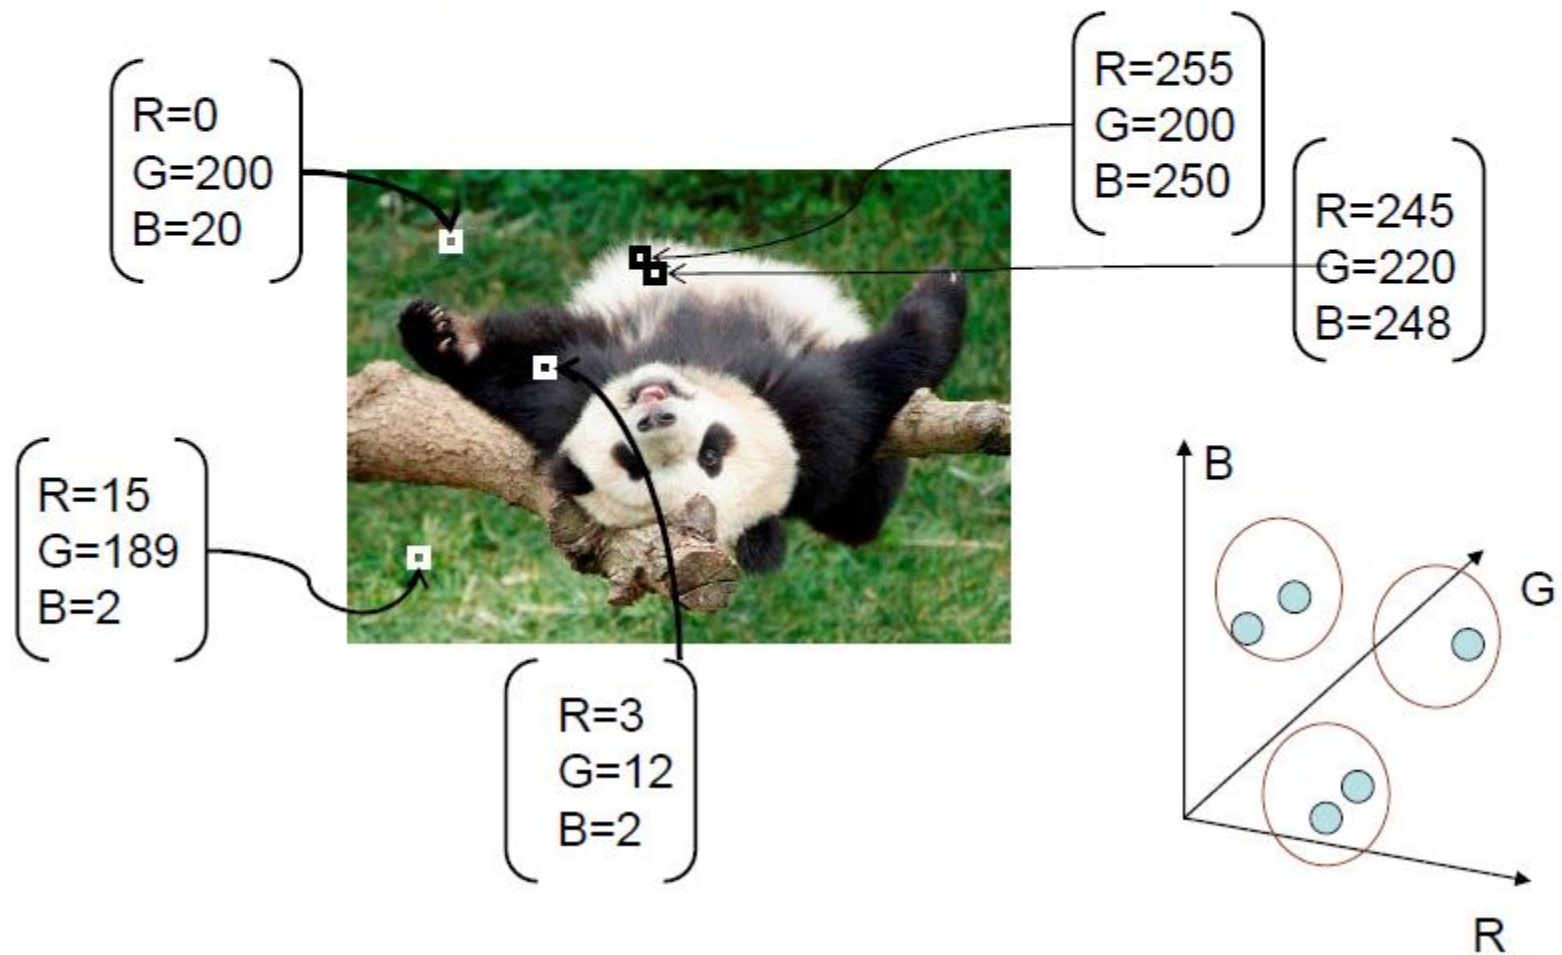
Segmentation as Clustering

- Pixels are points in a high-dimensional space
 - color: 3d
 - color + location: 5d
- Cluster pixels into segments



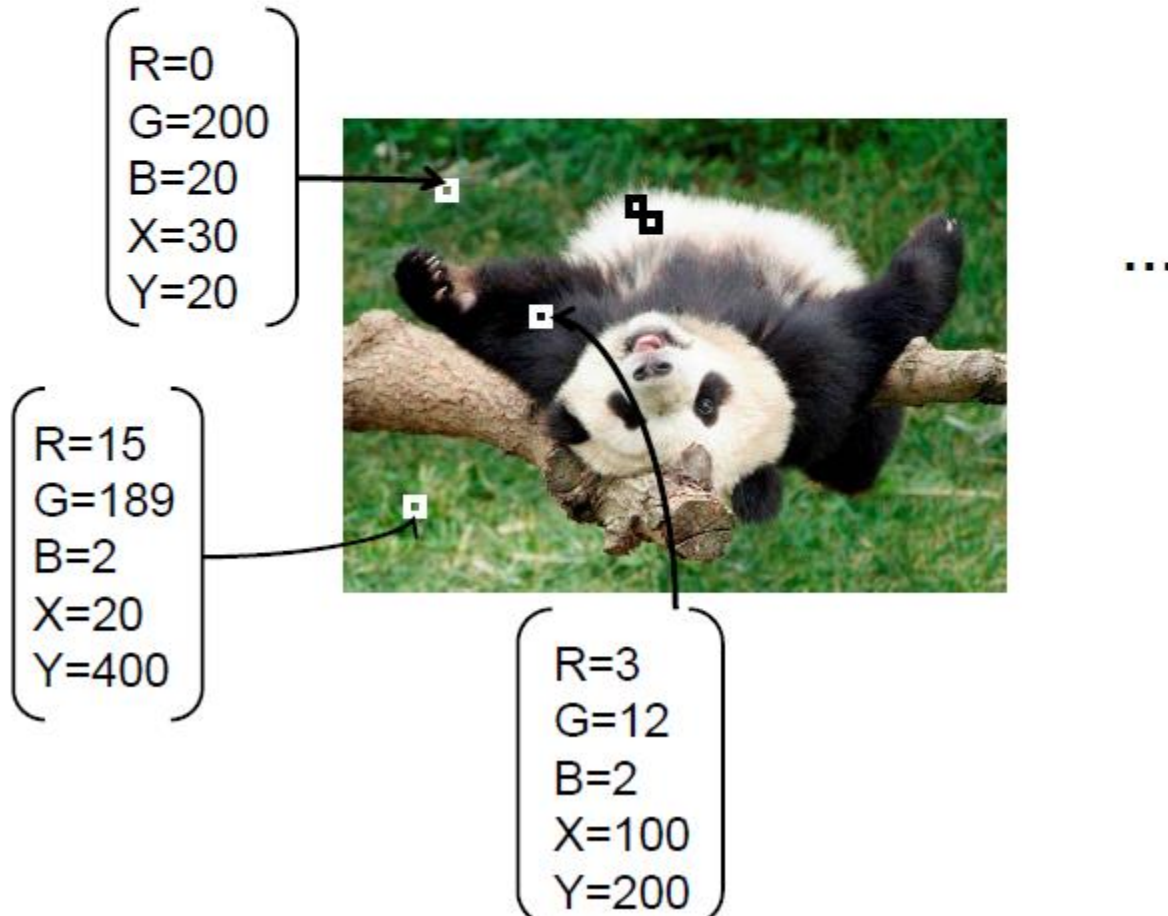
Segmentation as clustering

- Cluster similar pixels (features) together




Segmentation as clustering

- Cluster similar pixels (features) together



Mean-shift


- zhlukuje body obrazu (pixely) na základe podobnosti ich vzhľadu a blízkosti ich pozície pomocou konvergencie do lokálnych maxím spojeného súradnicového a intenzitného priestoru



Mean-shift

- v každej iterácii pre určitú pozíciu počíta gradient hustoty bodov v blízkom okolí a pohybuje sa v smere gradientu, až kým nedosiahne lokálne maximum
- tento proces je iniciovaný v každom bode výsledok
- súradnice lokálneho maxima pre každý bod
- zhlukovanie obrazových bodov (pixlov), ktoré dokonvergovali do rovnakého maxima s určitou toleranciou


Finding Modes in a Histogram



- How Many Modes Are There?
 - Easy to see, hard to compute

Mean Shift


[Fukunaga and Hostetler 1975, Cheng 1995, Comaniciu & Meer 2002]



Iterative Mode Search


1. Initialize random seed, and fixed window W
2. Calculate center of gravity ' x ' of W $|W| = \sum_{x \in W} x$
3. Translate the search window to the mean
4. Repeat Step 2 until convergence

Intuitive Description




Objective : Find the densest region
Distribution of identical billiard balls

Intuitive Description




Objective : Find the densest region
Distribution of identical billiard balls

Intuitive Description




Objective : Find the densest region
Distribution of identical billiard balls

Intuitive Description




Objective : Find the densest region
Distribution of identical billiard balls

Intuitive Description




Objective : Find the densest region
Distribution of identical billiard balls

Intuitive Description




Objective : Find the densest region
Distribution of identical billiard balls

Intuitive Description



Objective : Find the densest region
Distribution of identical billiard balls


Mean Shift Mode Detection



Updated Mean Shift Procedure:

- Find all modes using the Simple Mean Shift Procedure
- Prune modes by perturbing them (find saddle points and plateaus)
- Prune nearby – take highest mode in the window


Real Modality Analysis



**Tessellate the space
with windows**

Run the procedure in parallel


Real Modality Analysis



The blue data points were traversed by the windows towards the mode


Real Modality Analysis

An example



Window tracks signify the steepest ascent directions

Mean Shift Strengths & Weaknesses




Strengths :


- Application independent tool
- Suitable for real data analysis
- Does not assume any prior shape (e.g. elliptical) on data clusters
- Can handle arbitrary feature spaces
- Only ONE parameter to choose
- h (window size) has a physical meaning, unlike K-Means

Weaknesses :


- The window size (bandwidth selection) is not trivial
- Inappropriate window size can cause modes to be merged, or generate additional “shallow” modes → Use adaptive window size



(a)



(b)



Segmentation

Example




...when feature space is only gray levels...



Segmentation

Example




Segmentation

Example



Clustering-based segmentation

- Môžeme použiť K-means algoritmus




K-Means Clustering

- Vygeneruj začiatočné rozdelenie
- Nájdi centroid každého zhluku
- Pre každú farbu:
 - Vyrátaj vzdialenosť od každého centroidu
 - Prirad' k najbližšiemu zhluku
- Vyrátaj nové centroidy
- Opakuj, kým nie sú zhluky stabilné ($MSE < \text{prah}$)


K-Means Clustering




K-Means Clustering




K-Means Clustering




K-Means Clustering



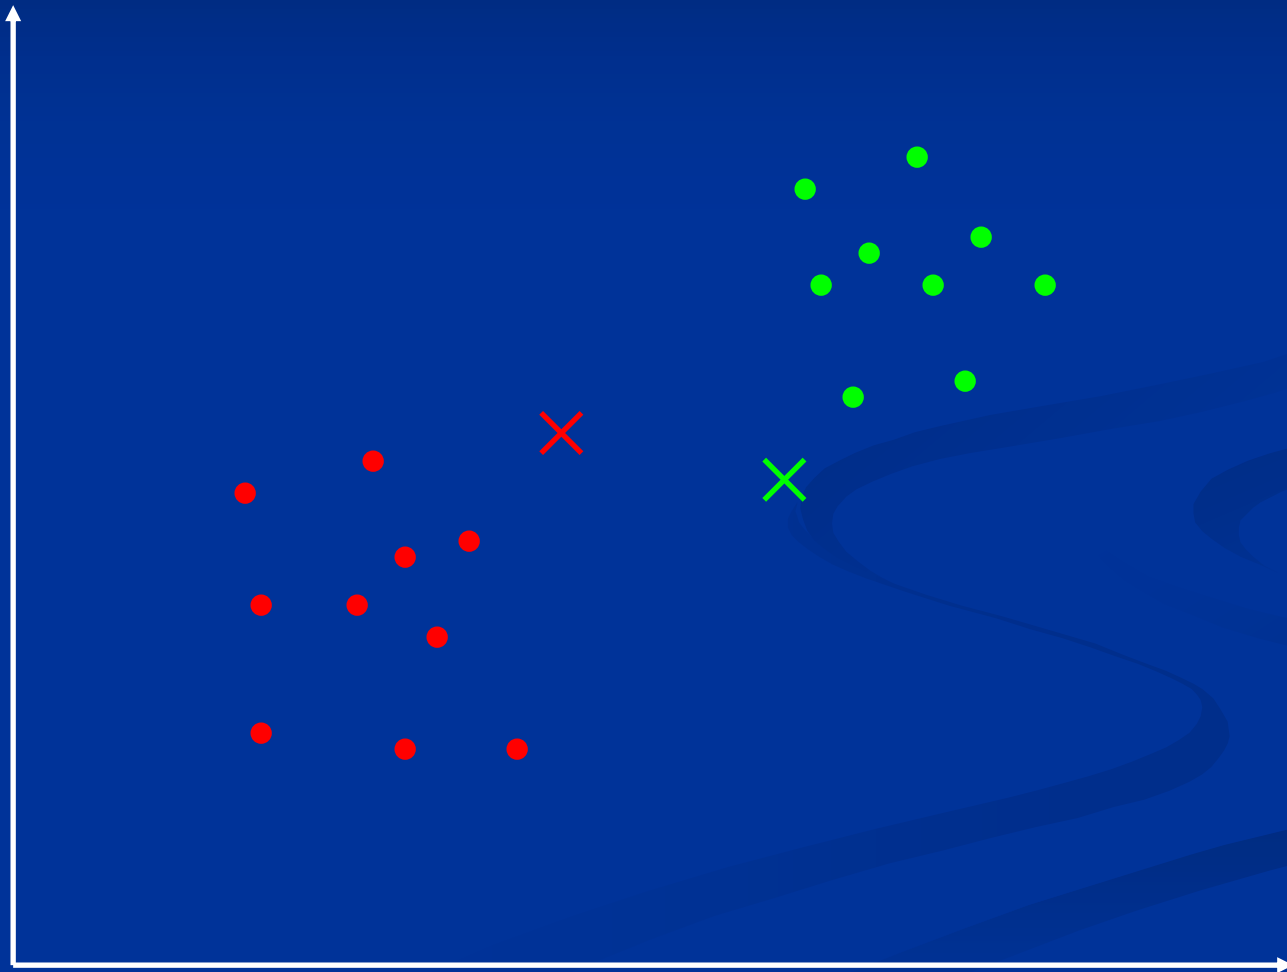
K-Means Clustering



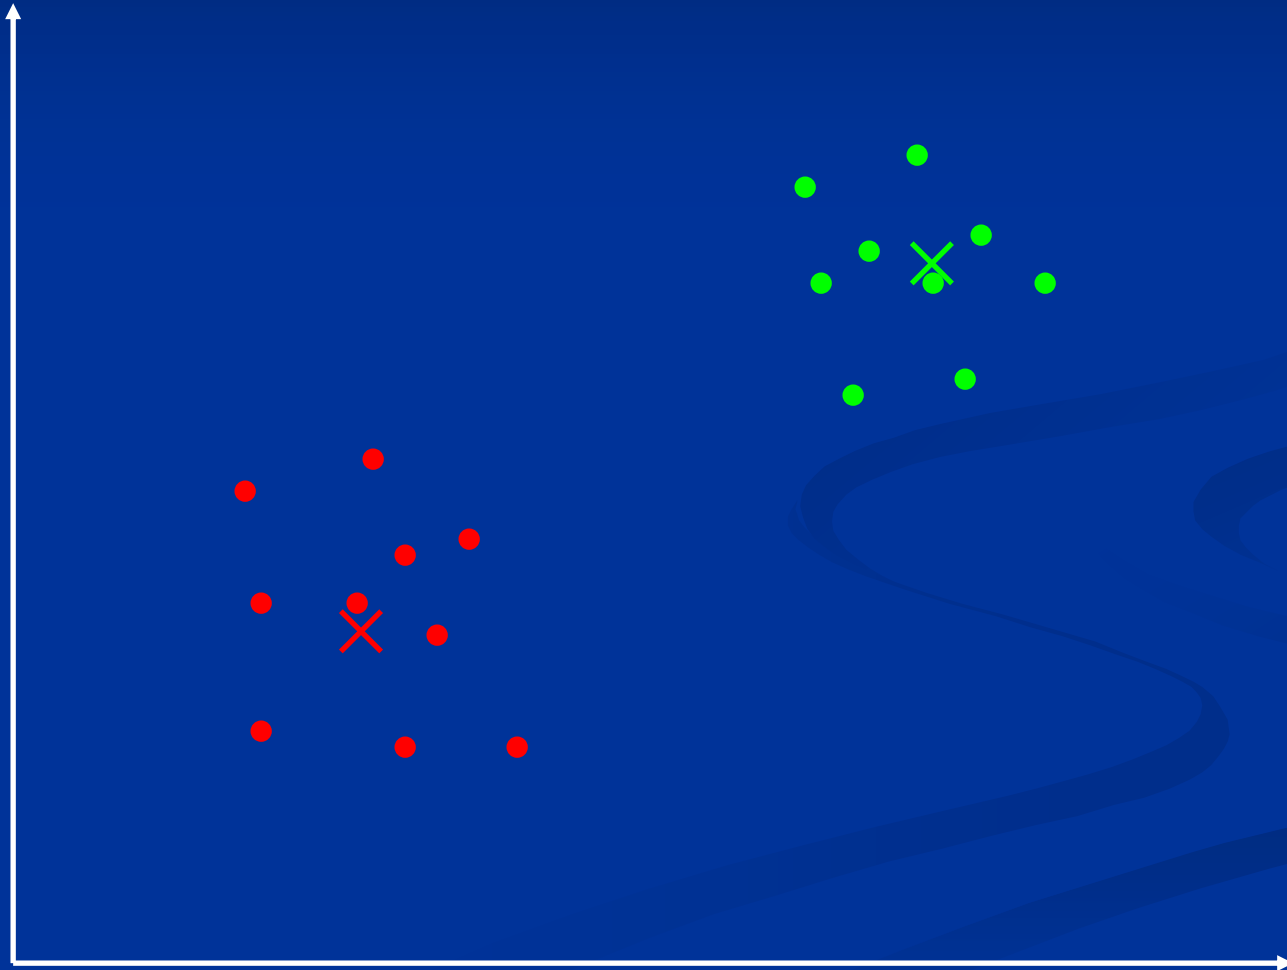
K-Means Clustering



K-Means Clustering



K-Means Clustering




Clustering: K-Means



$k=2$




$k=3$



Ako nájsť správne K

Zlomový bod:
spočítame WSS
pre rôzne K



- **Within Cluster Sums of Squares :**
$$WSS = \sum_{i=1}^{N_C} \sum_{x \in C_i} d(x, \bar{x}_{C_i})^2$$
- **Between Cluster Sums of Squares:**
$$BSS = \sum_{i=1}^{N_C} |C_i| \cdot d(\bar{x}_{C_i}, \bar{x})^2$$

C_i = Cluster, N_C = # clusters, \bar{x}_{C_i} = Cluster centroid, \bar{x} = Sample Mean

Clustering: K-Means




Note: Visualize segment with average color

Clustering-based segmentation

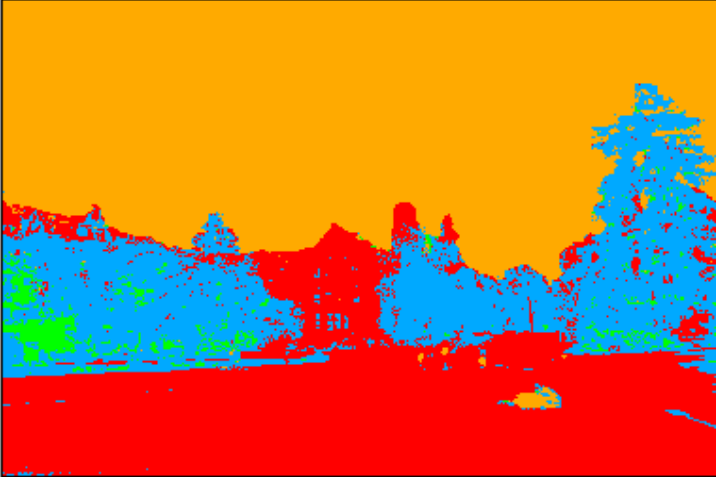
1. Select an image: 2. Select a processor: 3. Click

Options:
Init Method

640*480 (607,118): RGB(20,22,1)



Process done !



(228,26): RGB(255,170,0)

The image shows a software interface for K-means clustering. It features a top bar with three main sections: '1. Select an image:' with a dropdown menu containing 'imgs/Pa170028.jpg', '2. Select a processor:' with a dropdown menu containing 'KMCluster', and '3. Click' with a 'process>>' button. Below this, there are two main panels. The left panel displays the original image of a large building with a lawn and trees. Below it, the text '640*480 (607,118): RGB(20,22,1)' is shown. The right panel displays the segmented image, where the original colors are replaced by a few distinct colors (red, blue, yellow, green) representing clusters. Below it, the text '(228,26): RGB(255,170,0)' is shown. In the center, between the two panels, there is a section for 'Options:' with a label 'Init Method' and a text input field containing the value '0'. Below the options, the text 'Process done !' is displayed.

K-means clustering of color.

Clustering-based segmentation

1. Select an image: 2. Select a processor: 3. Click

Options:
Init Method

640*480 (636,95): RGB(102,130,151)

Process done !

(590,209): RGB(0,46,255)

K-means clustering of color

Clustering-based segmentation

- Clustering na základe farby a textúry





Original Images



Color Regions






Texture Regions



Clustering-based segmentation

- K-means rôzne variácie:
 - Rôzne spôsoby inicializácie.
 - Rôzne zastavovacie pravidla.
 - Dynamické metódy určovania správneho počtu grúp K pre daný obraz
- Problém: segmentácie na základe histogramov a klasteringu môžu produkovať nejednoznačné regióny.

Clustering-based segmentation




Examples from the UC Berkeley's Blobworld system.

Region growing – narastanie regiónu

- Narastanie regiónu začína s jedným pixelom potencionálneho regiónu (seed) a snaží sa narastať pridávaním pixlov na základe podobnosti.
- Prvý vybraný pixel môže byť buď prvý neoznačený pixel alebo z množiny „seeds“ určenej pre daný obraz
- Zvyčajne sa používajú štatistické texty na určenie ktorý pixel môže byť pridaný k skúmanému regiónu
 - Región je populácia s podobnými vlastnosťami

Region growing

image



segmentation



Techniky dodatočného spracovania narastania oblastí


- obrazy segmentované narastaním oblastí často obsahujú príliš veľa oblastí (slabé narastanie) alebo príliš málo oblastí (silné narastanie) ako výsledok neoptimálneho nastavenia parametrov.
- Na zlepšenie segmentačných výsledkov bolo vytvorených viacero techník dodatočného spracovania.

- Jednoduchšie techniky dodatočného spracovania znížia počet malých oblastí v segmentovanom obraze.
 - V jednom kroku sa odstraňujú hranice medzi susednými oblast'ami vzhľadom na ich kontrast a zmeny smeru pozdĺž hranice.
 - V druhom kroku sa výsledky prvého kroku modifikujú tak, aby pasovali presne so známymi obrazovými hranami.

Split-and-merge

1. Start with the whole image.
2. If the variance is too high, break into quadrants.
3. Merge any adjacent regions that are similar enough.
4. Repeat steps 2 and 3, iteratively until no more splitting or merging occur.

→ Idea: good
Results: blocky



Split-and-merge


Split and merge example



VIVB00420C720C79D01
Image Processing

82

Split and merge example




4087 regions

VIVB00420C720C79D01
Image Processing

84

Split and merge example




135 regions

VIVB0129C720C79D01
Image Processing

85


Split-and-merge




Split-and-merge



A satellite image.



A large connected region formed by merging pixels labeled as residential after classification.

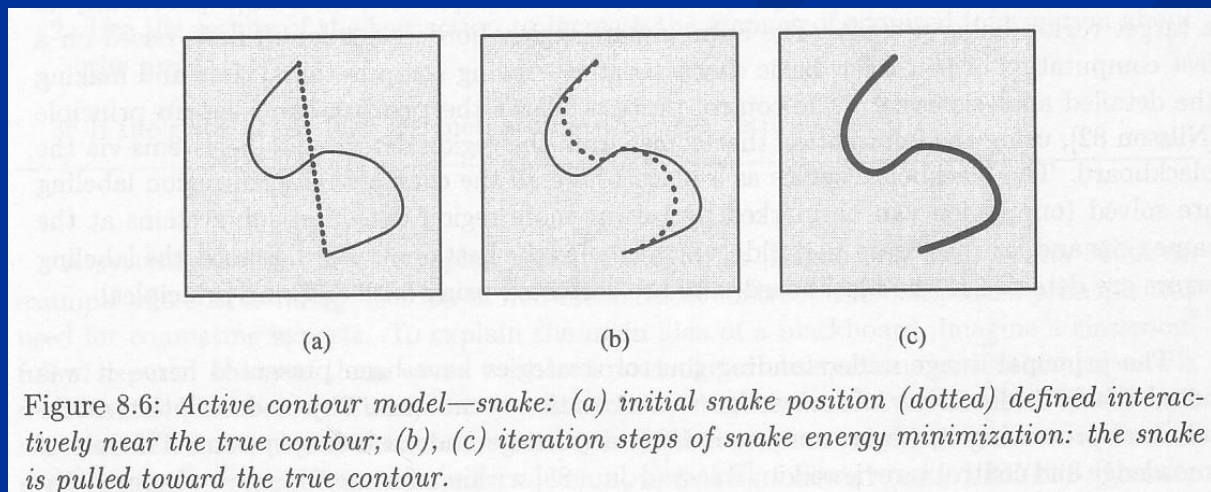


More compact sub-regions after the split-and-merge procedure.

Modely aktívnej hranice – hady (snakes)

- Had je spline, ktorý minimalizuje energiu – pričom energia závisí na jeho tvare a umiestnení v obraze.
- Lokálne minimá tejto energie zodpovedajú hľadaným vlastnostiam obrazu.
- Funkcia energie, ktorá sa minimalizuje je vážená kombinácia interných a externých síl.

- Modely aktívnej hranice sa používajú pri segmentácii, porozumení obrazu a pri analýze dynamických obrazových dát.
- Hady sami neriešia problém nájdania hranice, ale robia to v interakcii s užívateľom alebo nejakým vyšším procesom porozumenia.
- Táto interakcia musí špecifikovať počiatočný bod a približný tvar hranice.
- Apriórna informácia posúva hada k vhodnému riešeniu.
- Na rozdiel od ostatných modelov obrazu, had je aktívny, vždy si hľadá polohu s minimálnou energiou.



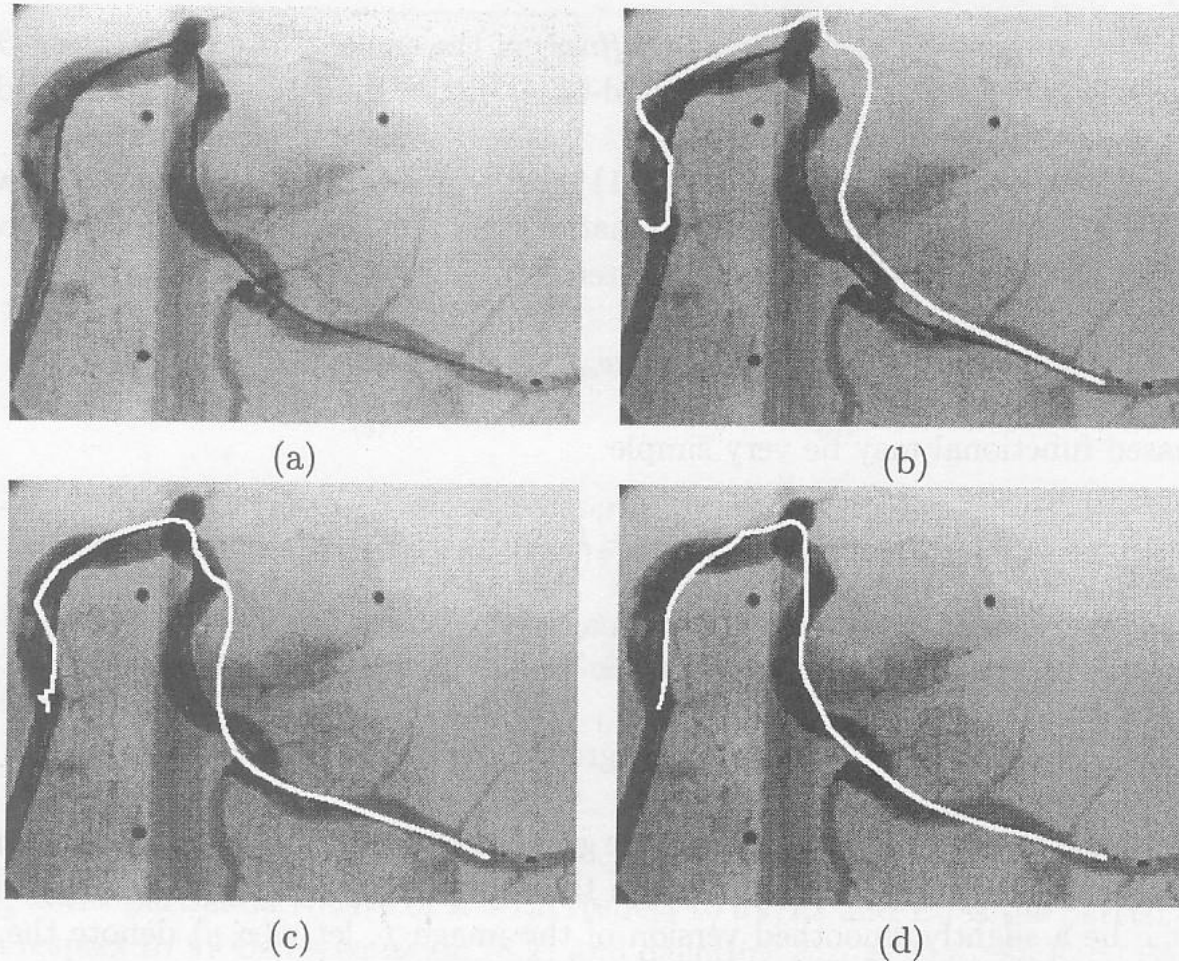


Figure 8.7: Snake-based detection of the untravascular ultrasound catheter (dark line positioned inside the coronary artery lumen) in an angiographic X-ray image of a pig heart: (a) original angiogram; (b) initial position of the snake; (c) snake deformation after 4 iterations; (d) final position of the snake after 10 iterations.

- Funkcia energie, ktorá sa minimalizuje, je vážená kombinácia vnútorných a vonkajších síl.
- Vnútorné sily vyplývajú z tvaru hada, kým externé sily z obrazu a/alebo z vyšších úrovní porozumenia.
- Hada je definovaný parametricky ako

$$\mathbf{v}(s) = [x(s), y(s)],$$

kde $x(s)$ a $y(s)$ sú súradnice pozdĺž hranice a s je z $[0,1]$.

- Minimalizovaná energia sa dá napísať ako

$$E_{hada}^* = \int_0^1 E_{hada}(\mathbf{v}(s)) ds = \int_0^1 \{ [E_{int}(\mathbf{v}(s))] + [E_{obraz}(\mathbf{v}(s))] + [E_{con}(\mathbf{v}(s))] \} ds$$

- kde E_{int} reprezentuje vnútornú energiu splajnu vzhľadom na ohýbanie (obsahuje parametre ako elasticitu a tvrdosť),

$$E_{int} = \alpha(s) \left| \frac{d\mathbf{v}}{ds} \right|^2 + \beta(s) \left| \frac{d^2\mathbf{v}}{ds^2} \right|^2$$

- E_{obraz} reprezentuje sily obrazu (obsahuje parametre, ktoré ťahajú hada k líniam, hranám a zakončeniam) a
- E_{con} reprezentuje vonkajšie ohraničujúce sily (napr. apriórna znalosť z vyššieho procesu).




Figure 8.8: A snake attracted to edges and terminations: (a) contour illusion; (b) a snake attracted to the subjective contour. Adapted from [Kass et al. 87b].


- Z Eulerovo-Lagrangeových podmienok vyplýva, že splajn, ktorý minimalizuje energiu, musí spĺňať

$$\frac{d}{ds} E_{v_s} - E_v = 0$$

kde E_{v_s} je parciálna derivácia E vzhľadom na $d\mathbf{v}/ds$ a

E_v je parciálna derivácia E vzhľadom na \mathbf{v} .

Rovnica sa zväčša rieši numericky.




(a)

(b)

Figure 8.9: *Snake growing: (a) lengthening in tangent direction; (b) energy minimization after a growing step.*


- Iný koncept pridáva ešte jednu energiu do vnútorných síl, keď pozerá na krivku ako na balón, ktorý sa nafukuje. To umožňuje hadovi prekonať izolované energetické doliny, pričom to dáva lepšie výsledky.




(a)

(b)


Figure 8.10: *Active contour model—balloon: (a) initial contour; (b) final contour after inflation and energy minimization. Adapted from [Cohen and Cohen 92].*



(a)



(b)



(c)

Figure 8.11: *B* alloon-based image segmentation of an ultrasound image of a fetal head: (a) initial position of the balloon; (b) balloon deformation after 10 iterations, (c) final position of the balloon after 25 iterations. Courtesy V. Chalana, MathSoft, Seattle, WA.