


## 7.

# Régió alapú szegmentálás

Kató Zoltán

<http://www.cab.u-szeged.hu/~kato/segmentation/>

# Szegmentálási kritériumok




Particionáljuk a képet az alábbi kritériumokat kielégítő régiókba (Pavlidis):

1.  $\cup S_i = S$  A régiók lefedik a teljes képet
2.  $S_i \cap S_j = \emptyset, i \neq j$  A régiók nem átfedőek
3.  $\forall S_i, P(S_i) = \text{true}$  Minden régió kielégíti a homogenitási kritériumot
4.  $P(S_i \cup S_j) = \text{false}$   
 $i \neq j, S_i \text{ adjacent } S_j$  Szomszédos régiók uniója nem elégíti ki a homogenitási kritériumot

- A szegmentáláshoz tehát definiálnunk kell egy homogenitási kritériumot
  - Milyen tulajdonságok figyelembevételével és
    - Intenzitás
    - Szín
    - Textúra
    - Mozgás
  - Hogyan definiáljuk a hasonlósági kritériumot úgy, hogy
  - A kialakult régiók megfeleljenek a képen látható objektumoknak vagy azok értelmes részeinek.

- A szegmentált képet címkézéssel állítjuk elő:
  - Egy adott régióhoz tartozó pixeleket azonos címkével (~szürkeárnyalat) jelöljük meg.





# Régiónnövelés (Region Growing)

Inicializáljuk a régiómagokat (seed point)

- Ezek kiválasztása alkalmazásfüggő
- Lehet egyszerűen az első még nem címkézett pixel


Növeljük a régiókat a szomszédos pixelek hozzáadásával a **homogenitási kritériumnak** megfelelően

- Szín távolság a szomszédoktól
- A régió belüli inhomogenitás mérésével
- Régió mérete vagy alakja, ...



(a) Start of Growing a Region

- Seed Pixel
- ↑ Direction of Growth



(b) Growing Process After a Few Iterations

- Grown Pixels
- Pixels Being Considered

- Homogenitási kritériumként alkalmazhatjuk pl. az alábbi statisztikai tesztet:

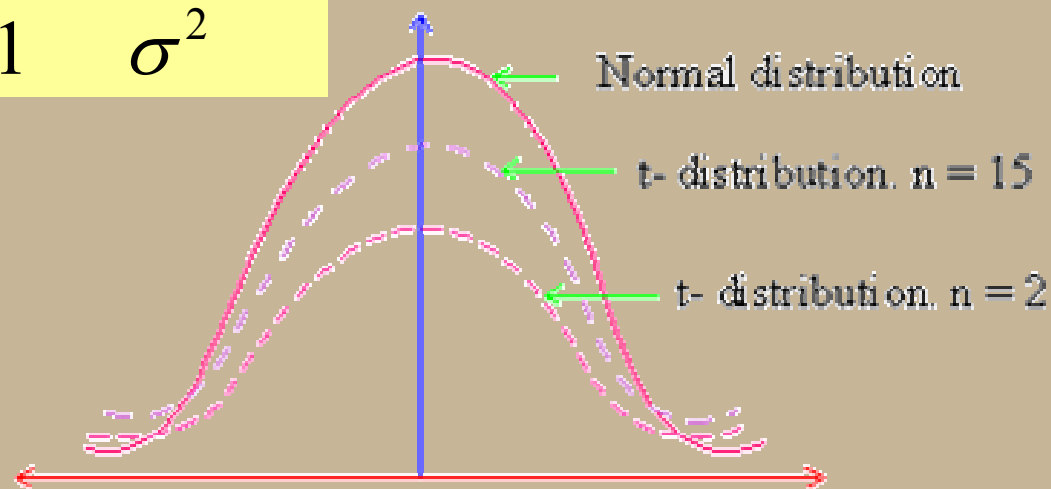
- Legyen  $R$  az aktuális régió, amely  $N$  pixelből áll.
- $P$  jelölje a vizsgált szomszédos pixel intenzitását.

$$\mu = \frac{1}{N} \sum_{(x,y) \in R} I(x,y) \quad \sigma^2 = \frac{1}{N-1} \sum_{(x,y) \in R} (I(x,y) - \mu)^2$$


- A  $\tau$  statisztika:

$$\tau = \sqrt{\frac{N}{N+1} \frac{(P - \mu)^2}{\sigma^2}}$$

- $(n-1)$  szabadsági fokú Student's eloszlást követ



- Egy megfelelő  $T$  küszöbszámot statisztikai táblázatból választhatunk a megfelelő szabadsági fokhoz és konfidencia szinthez
  - Ha  $\tau \leq T$ , akkor a vizsgált pixelt az  $R$  régióhoz adjuk
  - Ha  $\tau > T$ , akkor a vizsgált pixel egy másik (új) régióhoz tartozik.



# Split & Merge

1.  $P$  – homogenitási kritérium


2.  $R_i$  régiót osszuk fel 4 részre, ha

$$P(R_i) = \text{False}$$


3. Vonjuk össze az  $R_i$  és  $R_j$  szomszédos régiókat, ha

$$P(R_i \cup R_j) = \text{True}$$


4. Vége, ha nem lehet több régiót feldarabolni vagy összevonni.




(a) Whole Image



(b) First Split



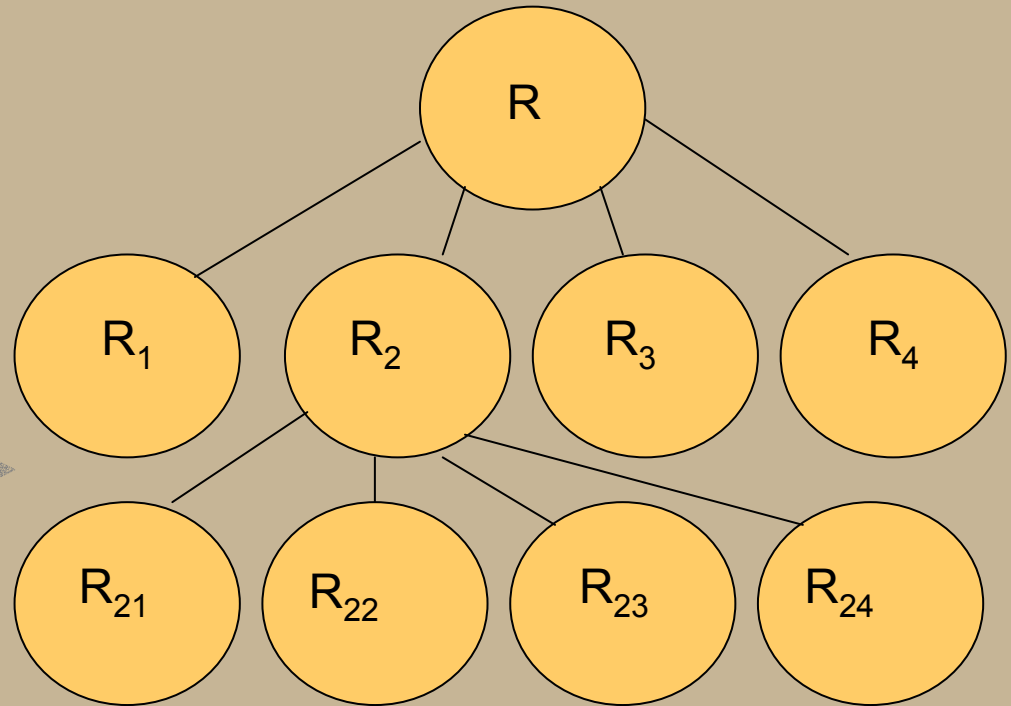

(c) Second Split



(d) Merge



# Quad-tree



# Split & Merge

**split**



**original**

**merge**



- Adott  $K$  klaszter:  $C_1, \dots, C_K$ .
- A klaszterek középértékét jelölje  $\mu_1, \dots, \mu_K$ .
- LSE (Least Square Error):

$$D = \sum_{k=1}^K \sum_{x_i \in C_k} \|x_i - \mu_k\|^2$$


- Az összes lehetséges particionálás közül válasszuk azt, amelyik minimalizálja  $D$ -t.
  - Sok lehetséges particionálás  $\rightarrow$  kereséssel nem határozható meg a minimum.

# K-means (Meng-Hee Heng)


1. Válasszunk 2 pontot ( $Y$  és  $Z$ ), amelyek a legmesszebb helyezkednek el egymástól a feature-térben. Ezek lesznek a kezdeti klaszter-középpontok.
2. A kép minden pontját rendeljük ahhoz a klaszterhez, amelynek a középpontja a legközelebb van.
3. Legyen  $D$  a maximális távolság, amely egy pont és az ő klaszter-középpontja között van. Jelölje  $X$  ezt a pontot.
4. Legyen  $q$  az átlagos távolság a klaszter-középpontok között.
5. Ha  $D > q/2$ , akkor legyen  $X$  egy új klaszter-középpont.
6. Ha új klaszter-középpont keletkezett, akkor  $\rightarrow$  2.

# K-means (Meng-Hee Heng)


1




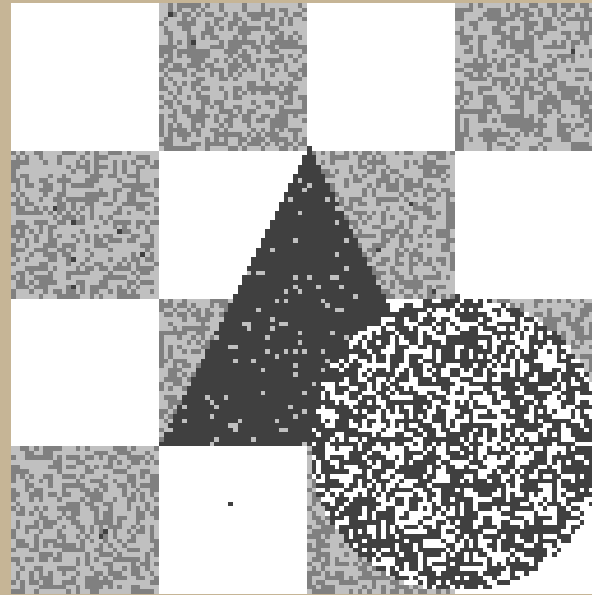

2





3



# K-means példa




K=4

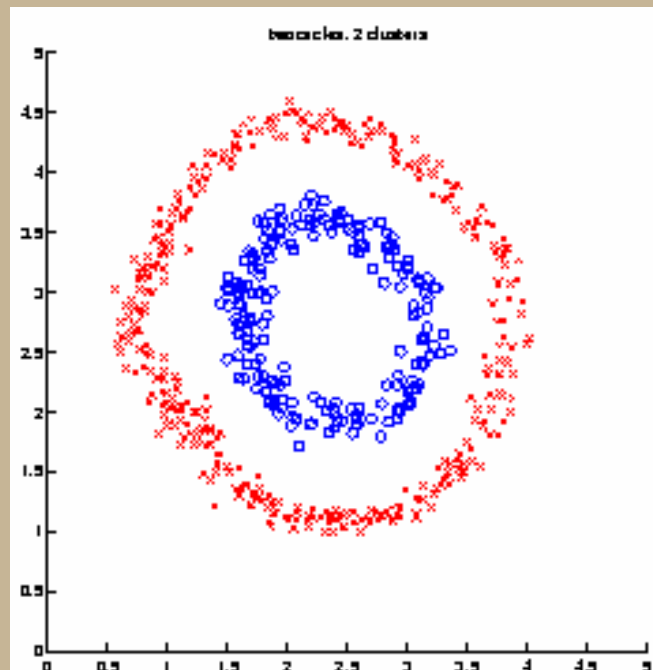


● Nem konvex klaszterek detektálására közvetlenül nem használható.


● → Spektrális klaszterezés




K-means



Spectral




OK



???

# Normalized Cut (Shi-Malik)

- Reprezentáljuk a képet gráfként:
  - a gráf pontjai pixelek vagy pixelek kis csoportja
  - a gráf éleihez rendelt súly a pixelek hasonlóságát jellemzi.
- Cél: Particionáljuk a gráf pontjait diszjunkt részgráfokra úgy, hogy
  - a hasonlóság egy részgráfon belül nagy,
  - de a részgráfok között kicsi.






# Minimális vágás


- Legyen  $G=(V,E)$  egy gráf.
  - Minden  $(u,v)$  élhez rendeljünk egy  $w(u,v)$ -vel jelölt súlyt, amely az  $u$  és  $v$  közötti hasonlóságot reprezentálja.
- A  $G$  gráfot két diszjunkt  $A$  és  $B$  részgráfra bonthatjuk úgy, hogy töröljük az  $A$  és  $B$  között átmenő éleket.
- Legyen a vágás költsége:
- $G$ -t particionálhatjuk úgy, hogy megkeressük a minimális vágást.

$$\text{cut}(A,B) = \sum_{u \in A, v \in B} w(u,v)$$



● A minimális vágás hajlamos kis méretű részgráfokat (~régiókat) előállítani (kevesebb él átvágása kisebb költséget jelent...)

● Normalizált vágás a megoldás:



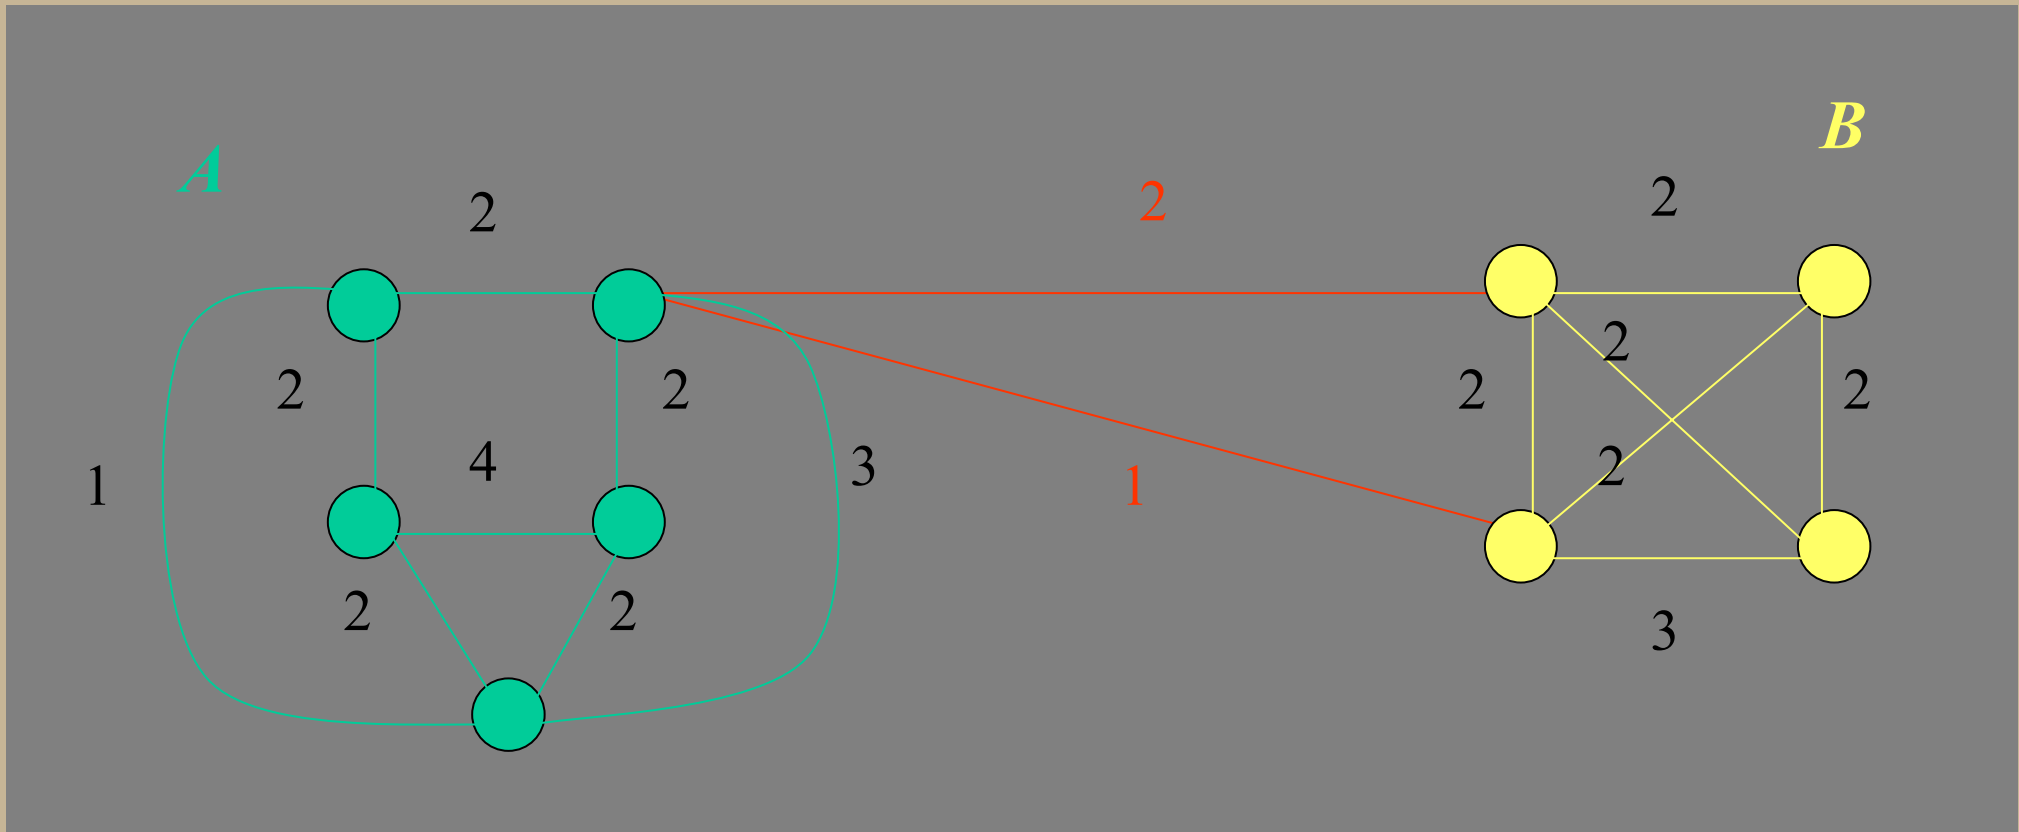
● Egy  $A$  részgráf mennyire erősen kapcsolódik az egész  $G=(V,E)$ -hez:

$$\text{asso}(A, V) = \sum_{u \in A, t \in V} w(u, t)$$

● Normalizált vágás:

$$\text{Ncut}(A, B) = \frac{\text{cut}(A, B)}{\text{asso}(A, V)} + \frac{\text{cut}(A, B)}{\text{asso}(B, V)}$$

# Normalizált vágás: Példa

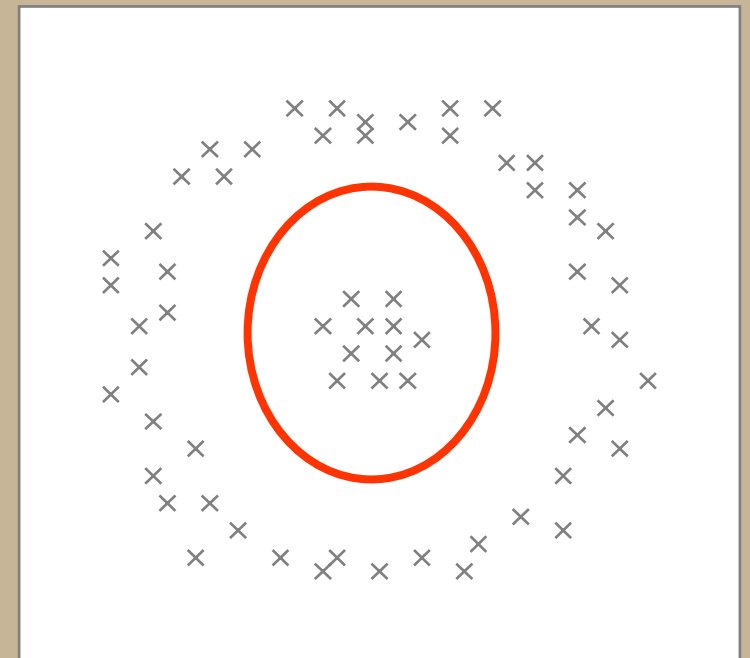
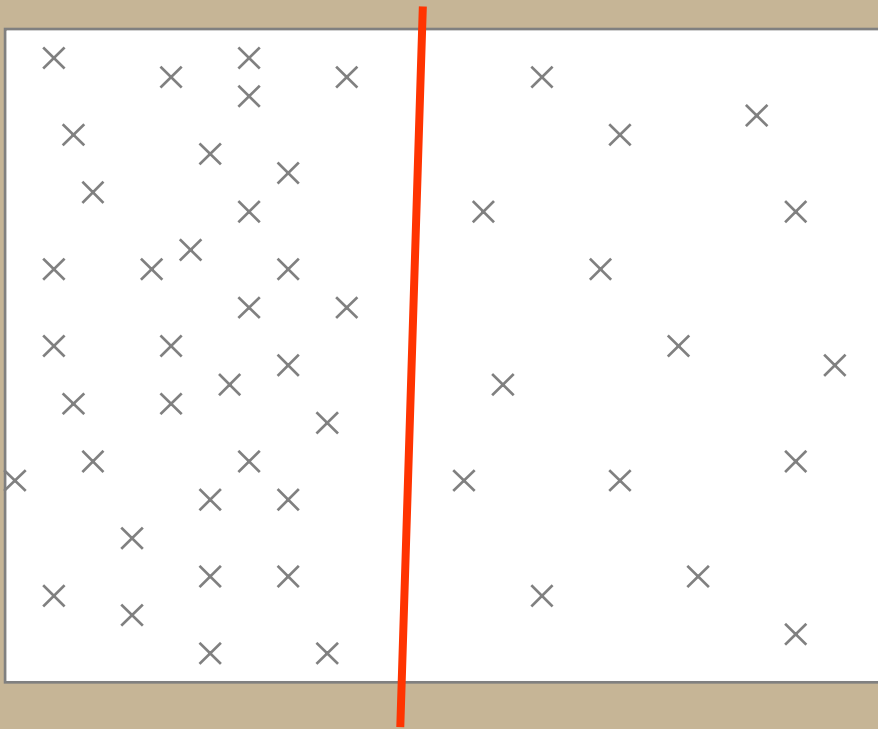


$$\text{Ncut}(A, B) = \frac{\text{cut}(A, B)}{\text{asso}(A, V)} + \frac{\text{cut}(A, B)}{\text{asso}(B, V)} = \frac{3}{21} + \frac{3}{16}$$

# Normalized Cut (NCut) kritérium

20

$$\hat{A} = \min_{A \subset V} (\text{Ncut}(A, \bar{A}))$$



**NP-Hard!**

- $W(i,j)$  – súly mátrix (szimmetrikus)
- $D(i,i)$  – az  $i$  csomópontához tartozó súlyok összege (diagonális)
- Levezetés után ezt kapjuk:
- Megoldás: általánosított sajátérték probléma.

$$D(i,i) = \sum_j w(i,j)$$

$$\min NCut = \min_y \frac{y^t (D - W)y}{y^t Dy}$$

$$1) y_i \in \{1, -b\} \quad 2) y^t D 1 = 0$$

**NP-Complete**

- Optimális megoldás a második legkisebb sajátérték
- Az  $y'$  megoldás valós lesz, amelyet diszkrét értékekké kell alakítani
  - Például 0 értékkel küszöböljünk

$$(D - W)y = \lambda Dy$$

# Hogyan definiáljuk a súlyokat?

$$w(i, j) = \exp\left(\frac{\|F_i - F_j\|^2}{\sigma_F}\right) \times \begin{cases} \exp\left(\frac{\|X_i - X_j\|^2}{\sigma_X}\right) & \text{if } \|X_i - X_j\|^2 < r \\ 0 & \text{otherwise} \end{cases}$$

- $X(i)$  - az  $i$  csomópont helye a képen
- $F(i)$  - az  $i$  csomópont tulajdonság-vektora
  - intenzitás, szín, textúra, mozgás, ...
- Vegyük észre, hogy  $w(i, j) = 0$  azokra a csomópontokra, amelyekhez tartozó pixelek a képen távol esnek egymástól.

1. Az input képből készítsük el a  $G=(V,E)$  gráfot, illetve a  $W$  hasonlósági ( $\sim$ súly) mátrixot.
  2. Oldjuk meg a  $(D-W)x=\lambda Dx$  általánosított sajátérték problémát
  3. A második legkisebb sajátvektor alapján particionáljuk  $G$ -t két részgráfra.
- Hogyan particionáljunk kettőnél több részre?
    - Rekurzívan futtassuk a fenti algoritmust a részgráfokra
    - Vagy használjuk a magasabbrendű sajátvektorokat

# NCut eredmények

