

# 4. Jellemző pontok kinyerése és megfeleltetése



**Kató Zoltán**

**Képfeldolgozás és Számítógépes Grafika tanszék  
SZTE**

**(<http://www.inf.u-szeged.hu/~kato/teaching/>)**

# Jellemzők és megfeleltetésük

- A képfeldolgozás, számítógépes látás számos területén felmerülő probléma egy látványról készült képpár közötti pontmegfeleltetések megkeresése.
  - Ehhez megbízható jellemzőket (tipikusan sarokpontokat) nyerünk ki a képekről
  - Majd a kinyert pontokat megfeleltetjük egymásnak.




# Megválaszolandó kérdések


- Melyek azok a pontok, amelyeket megbízható módon detektálhatunk a képeken?
  - Sarokpontok
- Hogyan tudjuk leírni/jellemezni a kinyert pontokat?
  - Invariáns jellemzők
- Hogyan feleltessünk meg két képről kinyert pontokat?
  - Jellemzők összehasonlítása, robusztusság

# Sarokpont detektálás


- Egy csúszóablakot vizsgálva ott lesz sarokpont, ahol az ablakot bármilyen irányba mozgatva nagy képfüggvény változást tapasztalunk



“sima” régió:  
egyik irányban  
sincs változás



“él”:  
az él irányában  
nincs változás




“sarok”:  
jelentős változás  
minden irányban

# Sarokpont detektálás: matematikai modell

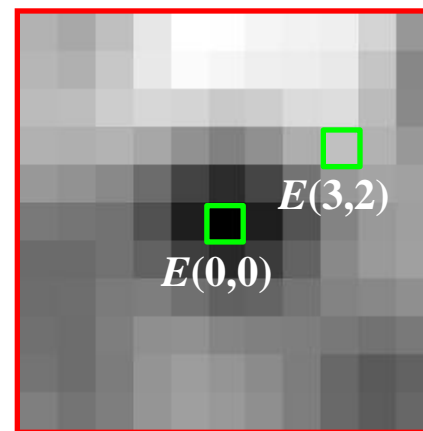
- A  $w(x,y)$  ablak tartalmának változása egy  $[u,v]$  eltolás hatására:
  - Lényegében auto-korrelációt számolunk

$$E(u, v) = \sum_{x,y} w(x, y) [I(x+u, y+v) - I(x, y)]^2$$

$I(x, y)$



$E(u, v)$




# $E(u,v)$ változása


1. Megfelelően változatos intenzitás tartalom  
→ jó lokális minimum

2. Élek mentén csak az egyik irányban van lokális minimum



3. Homogén területen  $E(u,v)$  alig változik





(a)




1.



2.




3.



# Az $M$ második momentum mátrix

- Az  $E(u, v)$  felszín lokális approximációja kvadratus alakban


$$E(u, v) \approx [u \ v] M \begin{bmatrix} u \\ v \end{bmatrix}$$



$$M = \sum_{x, y} w(x, y) \begin{bmatrix} I_x^2 & I_x I_y \\ I_x I_y & I_y^2 \end{bmatrix}$$

# M mint ellipszis jellemzése

- A tengelyek hosszát a sajátértékek adják
- A tengelyek irányát pedig az  $R$  forgatási mátrix adja




$$M = R^{-1} \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{bmatrix} R$$



# A sajátértékek jelentése

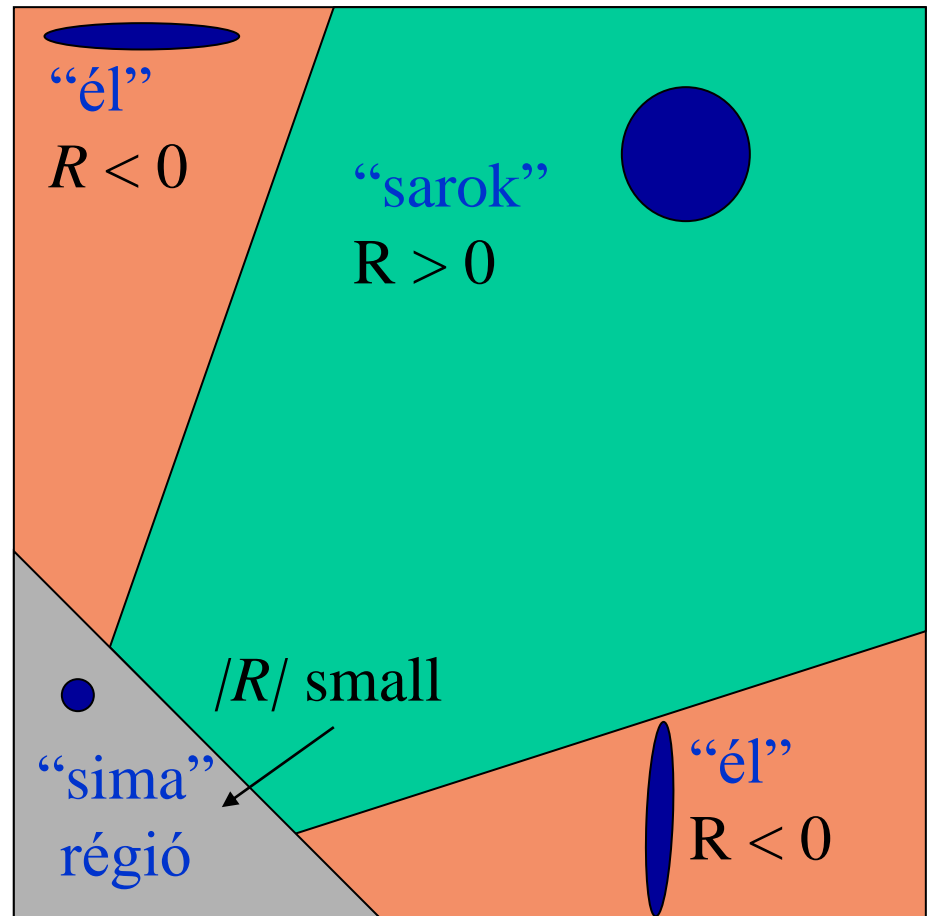
- A képünk pontjait osztályozhatjuk  $M$  sajátértékei alapján



# Sarkosságot jellemző függvény

$$R = \det(M) - \alpha \text{trace}(M)^2 = \lambda_1 \lambda_2 - \alpha (\lambda_1 + \lambda_2)^2$$

$\alpha$ : konstans (0.04 - 0.06)


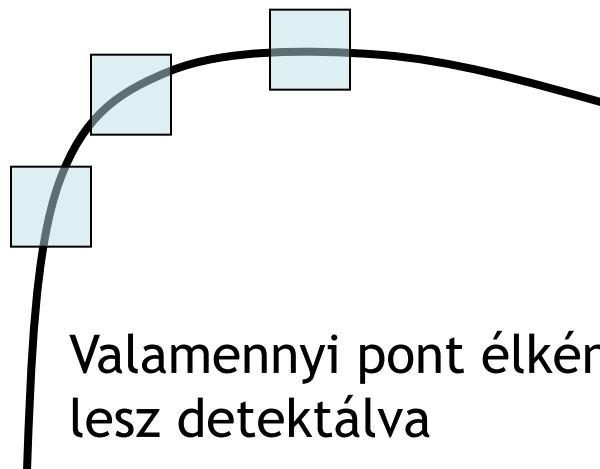


# Harris sarokdetektáló algoritmus

- 1) Számítsuk ki az  $M$  mátrixot minden egyes képpont feletti ablakban és ebből megkapjuk az  $R$  sarkossági jellemzőt
- 2) Keressük meg azokat a pontokat, amelyekre a sarkossági érték elegendően nagy ( $R > küszöb$ )
- 3) Tartsuk meg ezekből a lokális maximumokat (vagyis nyomjuk el a nem-maximumokat)

C.Harris and M.Stephens. “A Combined Corner and Edge Detector.”  
*Proceedings of the 4th Alvey Vision Conference*: pages 147–151, 1988.

# Harris: skálázásra nem invariáns




Sarokpont !

- **Hogyan detektálhatunk skála-invariáns, egymásnak megfeleltethető sarokpontokat?**


# Skála-invaráns detektálás

- Tekintsünk különböző méretű régiókat (pl. köröket) egy pont körül
  - Ezzel ekvivalens, ha megfelelő képpiramis változó felbontású szintjein azonos mérettel keresünk
- Az egymásnak megfelelő méretek hasonlóan néznek ki mindkét képen



# Skála-invaráns detektálás

- Hogyan válasszuk ki egymástól függetlenül a “megfelelő” köröket?

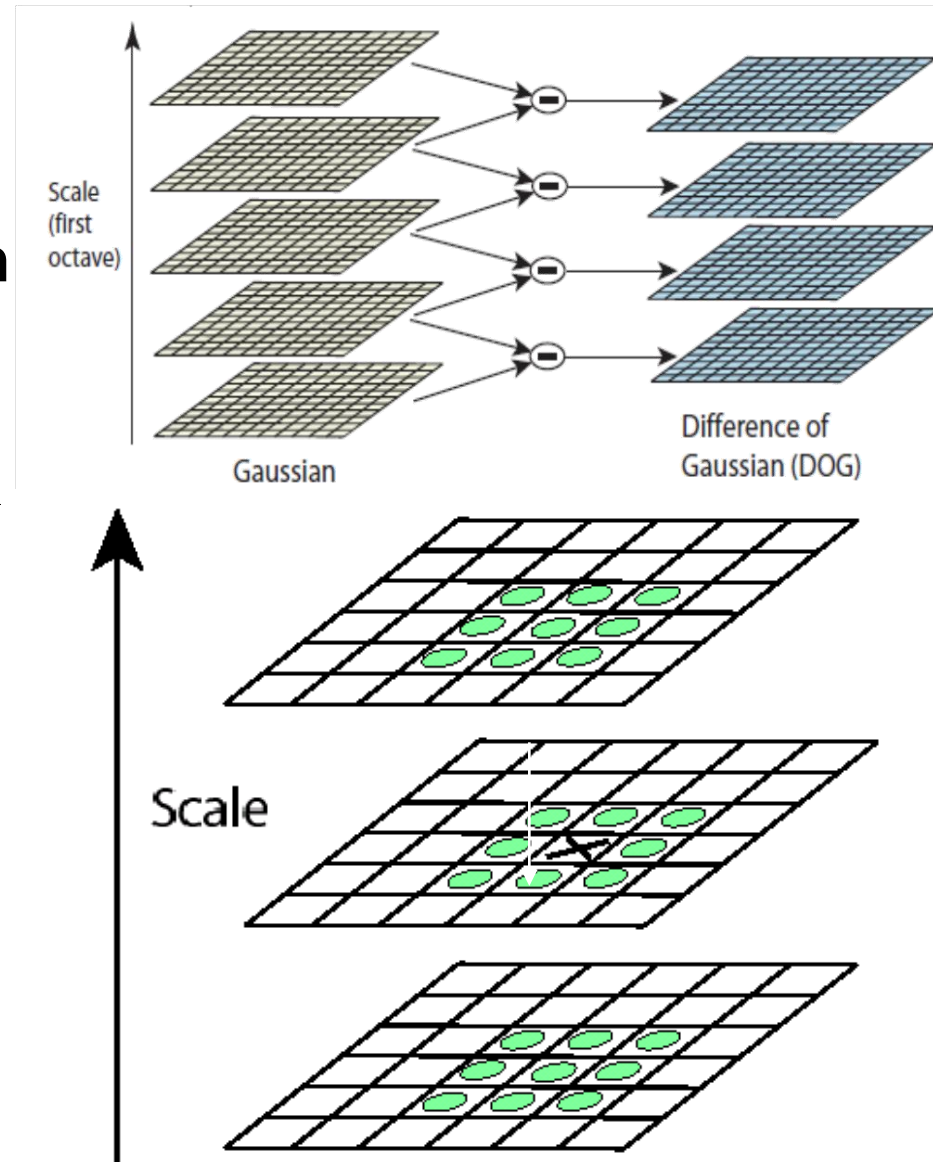


# Skála invariáns sarok-detektálás

- **Input:** két kép ugyanazon látványról nagy felbontásbeli különbséggel
- **Cél:** detektáljuk *ugynazon* jellemző pontokat mindkét képen *függetlenül* a képmérettől
- **Megoldás:** keressük a *maximumát* egy megfelelően konstruált függvénynek a *skála-* és *képtérben*

# Jellemző pontok kinyerése DoG segítségével

- Detektáljuk a difference-of-Gaussian (DoG) szélsőhelyeit skála-térben
  - (max, min) egy  $3 \times 3 \times 3$  szomszédságban
- Küszöböljük az értékeket
- Elimináljuk az él-válaszokat
- Az így kapott pontok listája:  $(x, y, \sigma)$






# Skála invariáns sarok-detektálás

- **Harris-Laplacian**<sup>1</sup>

*Keressük meg a lokális maximumait:*


- Harris sarokdetektor a képen
- Laplacian a skálatérben



- **SIFT (Lowe)**<sup>2</sup>

*Keressük meg a lokális maximumait:*

- Difference of Gaussians (DoG) a skála- és képtérben




<sup>1</sup> K.Mikolajczyk, C.Schmid. "Indexing Based on Scale Invariant Interest Points". ICCV 2001



<sup>2</sup> D.Lowe. "Distinctive Image Features from Scale-Invariant Keypoints". IJCV 2004

# Lokális leírók


- A detektált pontokat hogyan tudnánk leírni úgy, hogy az
  - invariáns és
  - egyedi legyen
- A kinyert pontok önmagukban nem jellemezhetőek jól
  - egyetlen intenzitás-érték nem elég stabil és egyedi
  - A pontok környezete már elég egyedi lehet, de az invariancia biztosítása nem triviális
- Tekintsük a pontot tartalmazó ablak tartalmát



# Képfoltok mint vektorok



from Hartley & Zisserman



Mindkét  $m \times m$  ablak tartalma ábrázolható egy  $m^2$  dimenziós vektorként.

Az ablakok tartalmát normalizálva a vektorok egységnyiek lesznek, miáltal könnyen összehasonlíthatóak a két vektor különbségként.

# Az ablakok tartalmának normalizálása

- Még azonos kamerák esetén is lehet eltérés a rögzített intenzitás értékekben (pl. eltérő gain/érzékenység).
- Ennek kiegyenlítésére célszerű a képeket normalizálni
  - Ezáltal az ablakokból képzett vektorok egységnyiek lesznek, így különböző képek között is összehasonlíthatóak

$$\bar{I} = \frac{1}{|W_m(x,y)|} \sum_{(u,v) \in W_m(x,y)} I(u,v)$$

Átlag pixelérték


$$\|I\|_{W_m(x,y)} = \sqrt{\sum_{(u,v) \in W_m(x,y)} [I(u,v)]^2}$$

Ablak magnitúdó

$$\hat{I}(x,y) = \frac{I(x,y) - \bar{I}}{\|I - \bar{I}\|_{W_m(x,y)}}$$

Normalizált pixelérték

# Hasonlósági mértékek



- **SSD: (Normalized) Sum of Squared Differences**
  - Minél kisebb annál jobban illeszkedik a két vektor

$$C_{\text{SSD}} = \sum_{(u,v) \in W_m} [\hat{I}_1(u,v) - \hat{I}_2(u,v)]^2 = \|w_1 - w_2\|^2$$

- **NC: Normalized Correlation**
  - Minél nagyobb, annál jobban illeszkedik a két vektor

$$C_{\text{NC}} = \sum_{(u,v) \in W_m} \hat{I}_1(u,v) \hat{I}_2(u,v) = w_1 \cdot w_2 = \cos \theta$$

# Képfolt alapú leíró invarianciája

- Fotometriai invariancia a normalizálással elég jól teljesül
- Azonos méretű ablakok hasonlíthatók össze → skálafüggő
- Azonos állású (vagyis rásztersorokra illeszkedő) ablakok hasonlíthatók össze → orientáció függő
- Összességében tehát
  - nincs geometriai invariancia,
  - van részleges fotometriai invariancia

# SIFT: SCALE INVARIANT FEATURE TRANSFORM




# SIFT - Scale Invariant Feature Transform

- Skála- és irányfüggetlen fotometriailag invariáns pontleírókat állít elő az alábbi főbb lépésekben:

## 1. skála meghatározása (ez már megtörténik a pontok detektálása során)

- DoG szélsőhelyek térben és skálában



## 2. lokális orientáció a domináns gradiens irány

## 3. Az így kapott skála és orientáció minden egyes kinyert pontban egyértelműen meghatároz egy lokális koordinátarendszert




- Minden további számítás ebben a koordinátarendszerben történik, így a kapott leírók skála- és irányfüggetlenek lesznek

## 4. Számítsunk **gradiens irány-hisztogramokat** több kisebb ablakban, amiből leíró vektort képezünk.




# Jellemző pontok kinyerése

- DoG skálatérben válasszunk ki minden pontot, ami a  $3 \times 3 \times 3$  környezetben szélsőhely (max, vagy min)
- Töröljük az instabil pontokat
  - Alacsony kontraszt
  - Nem elég magas sarkossági jellemző
- Megkapjuk a képi pozíciót  $(x,y)$  és a hozzá tartozó skálát  $(\sigma)$





# Kinyert jellemző pont




- **Keypoint location = extrema location**
- **Keypoint scale is scale of the DOG image**


# Orientáció




- A kinyert pontokhoz rendeljük egy konzisztens irányt
  - Minden ponthoz a hozzá tartozó skálán számoljunk gradienst




A képpiramis megfelelő skálájáról vett (Gauss simított) kép





gradiens  
magnitúdo




Gradiens  
irány



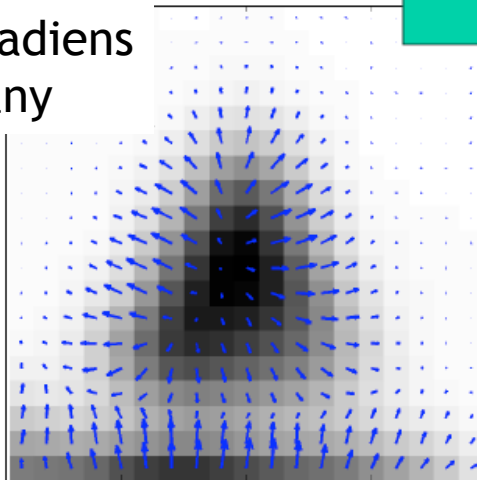
# Orientáció




Súlyozott gradiens  
magnitúdó



Gradiens  
irány





Súlyozott irány-hisztogram: Minden csoport azon gradiens-magnitúdók súlyozott összegét tartalmazza, amelyek a csoportba eső irányúak




Irány csoportok: 10 fokonként tekintsük a gradiens vektorokat. Ez összesen 36 csoportot jelent.


# Orientáció




Súlyozott gradiens  
magnitúdó



Gradiens  
irány



**Írány kiválasztás:** Minden olyan irányt kiválasztunk, amelyek a csúcsérték 80%-n felül van és minden ilyen irányhoz létrehozunk egy pontot (tipikusan a pontok 15%-a több irányú)




20-30 degrees

Jelen példában a pont iránya 25 fok lesz, mivel csúcs a 20-30 fokos csoportban van, és nincs másik domináns irány.


# SIFT leíró

- Eddig minden jellemző ponthoz tartozik:
  - pozíció
  - skála
  - magnitúdó
  - irány
  
- Mivel írhatnánk le a pont körüli régiót?



# SIFT leíró

- Tekintsünk egy 16x16 ablakot a gradiens-mezőn, amit tovább osztunk 4x4 blokkokra.
- Számítsunk a 4x4-es mintákon 8 irányban hisztogramot
- Alkalmazzunk Gauss súlyozást a középpont körül, aminek szórása= $0.5 \times \sigma$  (a jellemző pont skálája)
- $4 \times 4 \times 8 = 128$  dimenziós vektor leíró



# SIFT leíró - fotometriai invariancia

- **Lineáris (globális) megvilágítás változás:**
  - Az intenzitásértékek nagysága (gain) önmagában nem befolyásolja a gradienst
  - A vektorok egységnyivé normalizálása feloldja a kontrasztbeli különbségeket
- **Nem lineáris (lokális) megvilágítás változás:**
  - Telítettség inkább a magnitúdót mint az irányt befolyásolja.
  - Küszöböljük a gradiens magnitúdót 0.2-vel ( $[0, 1]$ -re normált értékeket feltételezve), majd normalizáljunk újra.
    - empirikusan meghatározott érték 3D objektum többféle megvilágítása alapján
- **Az legnépszerűbb, rendkívül robusztus pontleíró [Mikolajczyk & Schmid 2005]**




# SIFT leírók megfeleltetése

- L2 távolság alapján a legközelebbi szomszédal párosítjuk
- Hogyan szűrjük ki a rossz megfeleltetéseket (pl. ha nincs megfelelő párja egy pontnak)?
  - Küszöböljük az L2 távolságot → rossz teljesítmény
  - Küszöböljük inkább az arányt → jó teljesítmény

legjobb megfeleltetés  
2. legjobb megfeleltetés

# Képrészletek felismerése



# Regisztráció panoráma képhez



[Brown & Lowe 2003]

# Felhasznált anyagok

- Trevor Darrell: C280, Computer Vision  
<http://www.cs.cmu.edu/afs/cs/academic/class/15385-s06/lectures/ppts/>
- David Lowe
- James Hays: CS 143 Computer Vision, Brown University
  - <http://www.cs.brown.edu/courses/cs143/>
- További források az egyes diákon megjelölve