



Lokálne príznaky

Počítačové videnie 2

Zuzana Haladová

Príznaky

Príznaky- Lokálne vs. Globálne

Globálne: tvar, farba, textúra

=> jedna informácia pre celý obraz

Lokálne:

=> informácia o bode a jeho okolí

Problém

Chceme nájsť na obrázku konkrétny objekt
(Teda „Zuzkin hrnček“ a nie „hrnček“).

Využijeme lokálne príznaky vypočítané v
konkrétnych dvoležitých bodoch na obrázku



Príznaky

Príznaky by mali byť v najlepšom prípade invariantné ku:

- zmenám osvetlenia
- škále, rotácií
- perspektívnym transformáciám

a tiež by sme hodnoty týchto príznakov chceli použiť na matching, detekciu a 3D rekonštrukciu

Príznaky

Ako identifikujeme body z ktorých extrahujeme najlepšie príznaky ?

Mali by sa ľahko extrahovať

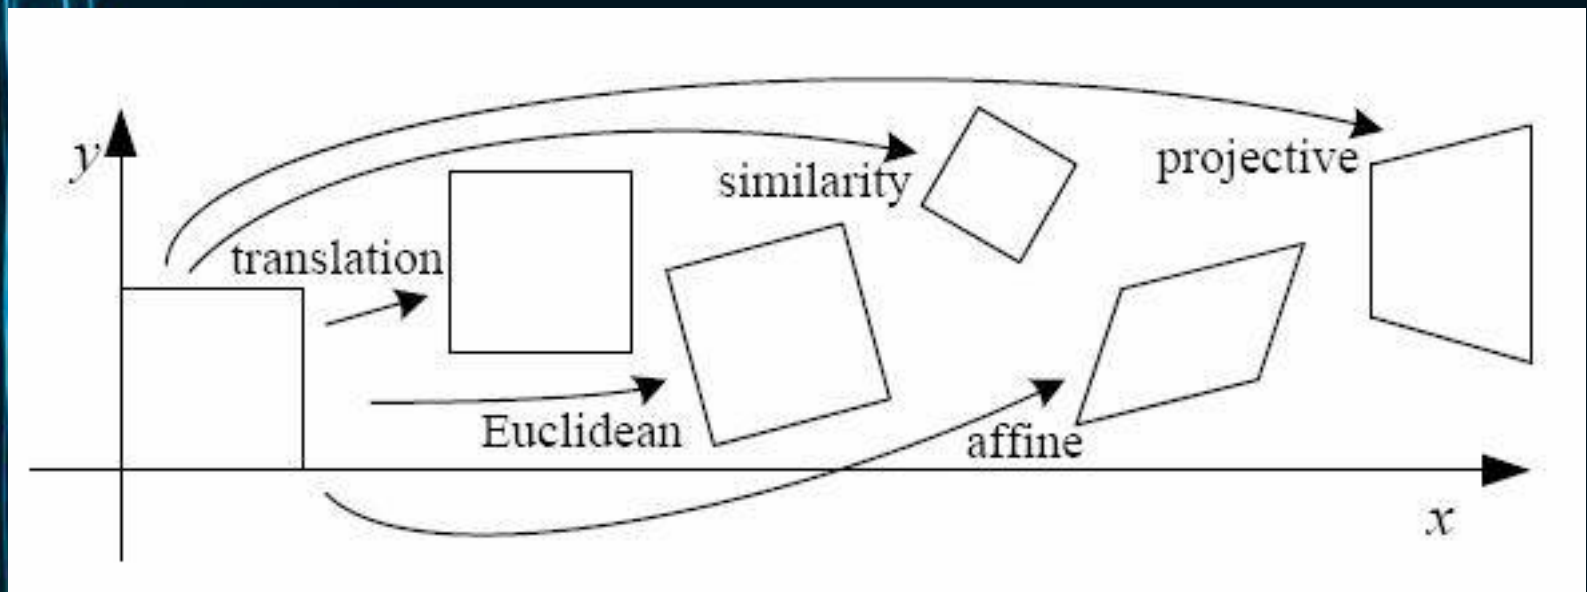
- mali by byť invariantné a odolné voči
Šumu

Zmene osvetlenia

Uniformnému škálovaniu

Ako zostrojiť dobré, invariantné príznaky?

-maly by sa dať ľahko porovnať s veľkou databázou príznakov.



Algoritmy

Algoritmy využívajúce lokálne príznaky:

SIFT, SURF, Daisy....

2 časti algoritmu:

Detektor ==> nájdenie zaujímavých bodov v obrázku (Harris corner, FAST)

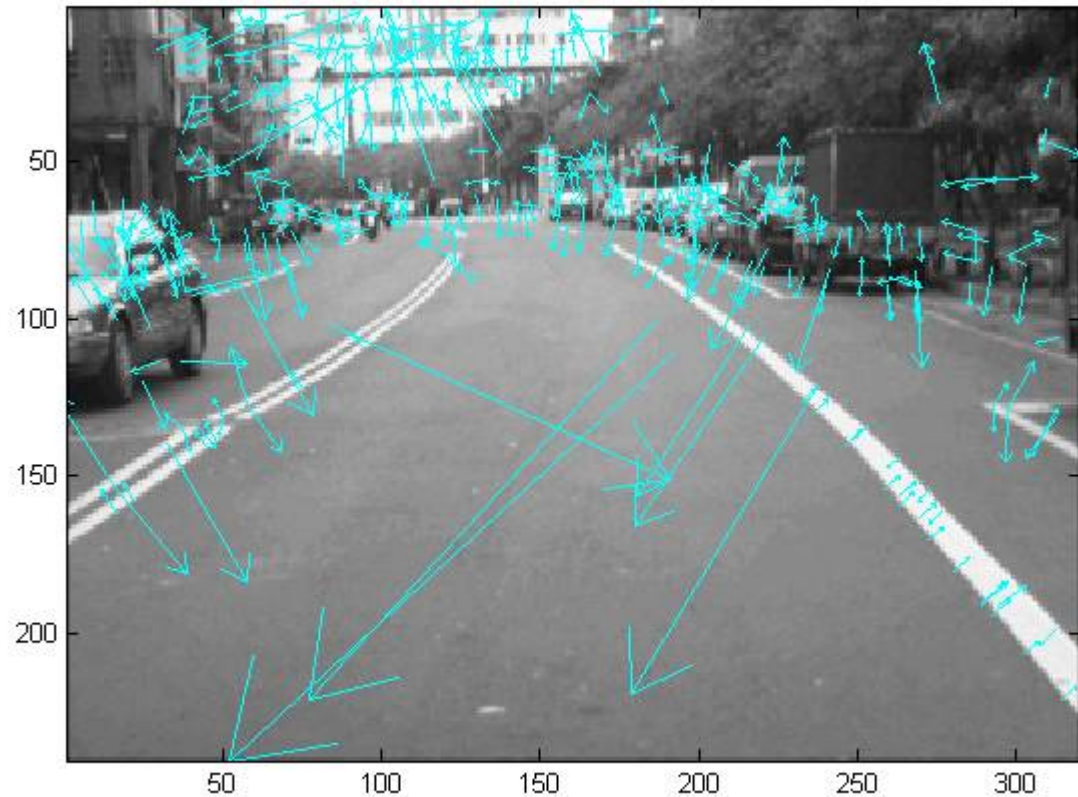
Descriptor ==> vytvorenie popisu zaujímavých bodov

Deskriptor - celočíselný (SIFT, SURF, Daisy)


- binárny (BRIEF, ORB)

Detektory


Harris corner, detektor SIFTu, SURFu, Daisy




Corner point



“flat” region:
no change in
all directions



“edge”:
no change along
the edge
direction



“corner”:
significant
change in all
directions

Harris corner detector: Steps

1. Compute image derivative
2. Compute second moment matrix M
3. Gaussian filtering of M

$$M = \begin{bmatrix} \sum I_x I_x & \sum I_x I_y \\ \sum I_x I_y & \sum I_y I_y \end{bmatrix} = \sum \begin{bmatrix} I_x \\ I_y \end{bmatrix} [I_x \ I_y] = \sum \nabla I (\nabla I)^T$$







Image
derivatives



Square of
derivatives



Gaussian
filter




I_y

$g(I_x I_y)$

$g(I_x I_y)$

Eigenvalues

Classification of image points using eigenvalues of M :




Harris corner detector: Steps

4. Compute corner response function R
5. Threshold R
6. Find local maxima of response function (nonmaximum suppression)

Corner response function


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

α : constant (0.04 to 0.06)





Compute corner response R



Take only the points of local maxima of R





$$\begin{array}{cc}
 S_{\sigma}(R_x^2 + G_x^2 + B_x^2) & S_{\sigma}(R_x R_y + G_x G_y + B_x B_y) \\
 S_{\sigma}(R_x R_y + G_x G_y + B_x B_y) & S_{\sigma}(R_y^2 + G_y^2 + B_y^2)
 \end{array}$$



SIFT


SIFT

detektor + deskriptor

detektor:

Hľadá zaujímavé body v DoG priestore

Scale space == Invariantnosť voči škálovaniu



SIFT

SIFT

Zaujímavé body hľadá v 26 okolí v DoG.

Hľadajú sa minimá a maximá
=> lokálne extrémny v 26 okolí

Odstránia sa slabé body



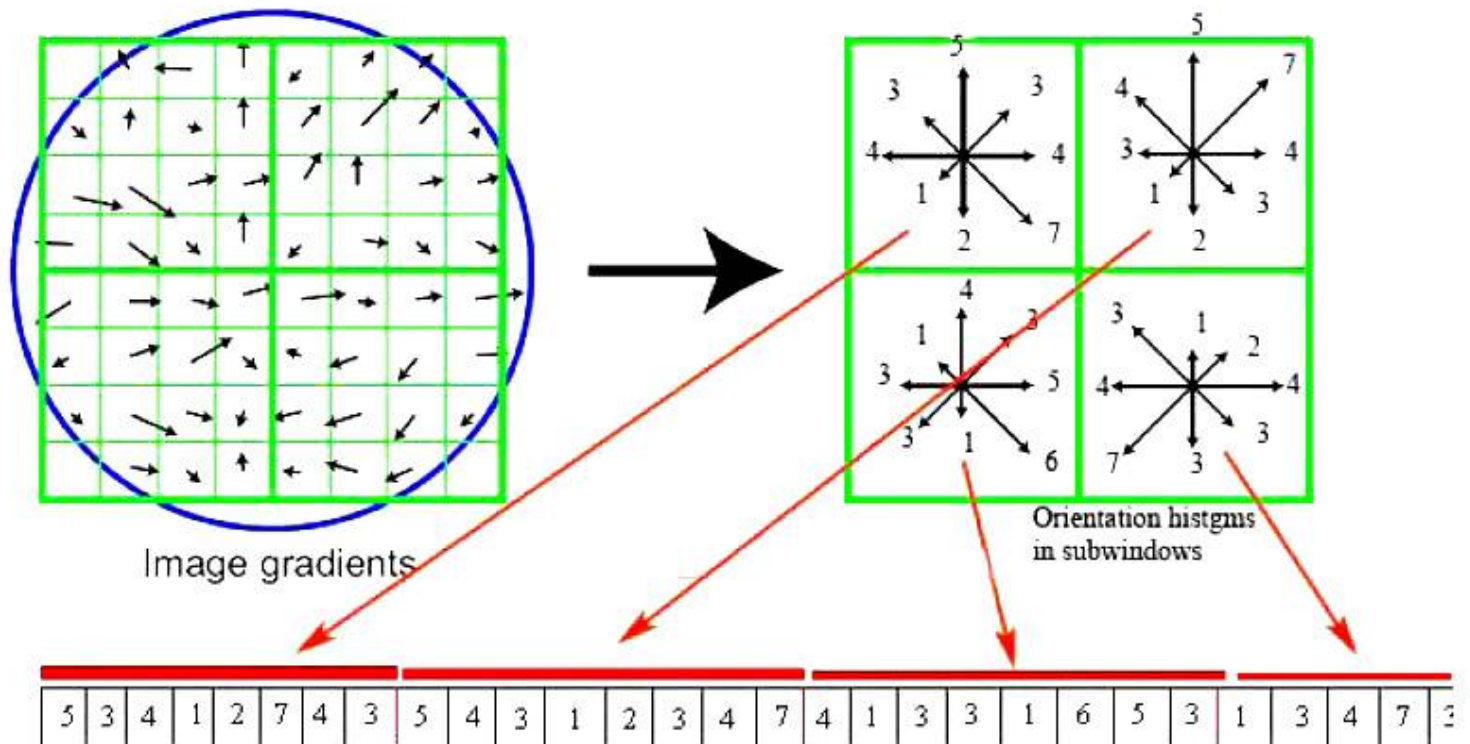


Figure 3. Example of a scale-space before the DoG computation.

SIFT

SIFT

deskriptor: 128 hodnôt: 16 x 8 hodnôt histogramu orientácií gradientov



128-element SIFT feature vector

SURF


SURF

Bay et al. 2002

Detektor:

Namiesto vytvárania Scalespace pyramídy filtruje obrázkov rôznymi veľkosťami Box Filtrov

Box Filter = Aproximácia parciálnej derivácie druhého rádu Gausiánu v smere y a x, y



SURF

SURF

Deskriptor:

Suma Haar- wavelet odoziev vo vertikálnom smere
horizontalnom smere


Suma absolútnych hodnôt Haar wavelet odoziev vo
vertikálnom smere
Horizontalnom smere

4 príznaky x 16 oblastí = 64 hodnotový vektor

DAISY

DAISY
































- Histogram orientací Gradientov
- deskriptor délky 200



Found Occlusions

Missed Occlusions

False Occlusions



Deskribtory

Deskribtory:

BRIEF, Lazy, ORB

BRIEF

BRIEF, Lepetit 2010

Deskriptor:

- jeden z prvých binárnych deskriptorov
- nieje invariantný rotácii
- => ORB (OpenCV) invariantný rotácii

- porovnáva intenzitu dvojíc pixlov v okolí zaujímavých bodov => bitov7 deskriptor

- 256 / 128 bitov

- <http://www.youtube.com/watch?v=-ZNYoL8rzPY>

Matching

Porovnávanie príznakových vektorov pre zaujímavé body:

L2 norma(euklidovská vzdialenosť) pre celočíselné vektory

Hammingova vzdialenosť pre binárne vektory (bitová vzdialenosť)

Ohodnocovanie dobrých párov:

Second nearest neighbour

Vzdialenosť naj. páru = $D1$

Vzdialenosť 2. naj páru = $D2$

$$D1 < 0.6 * D2$$

Využitie

CASE STUDY:

Rozpoznávanie maliarskych plátien na fotografiách

Podmienky:

Rôzne fotoaparáty, denná doba

Rozostrenie, Prekrytie, Viac obrazov na fotografii



Využitie

CASE STUDY:


Performance:

90 % SIFT a SURF

SURF je výrazne rýchlejší

Problémy:

Táto metóda by nefungovala na
maľbách niektorých štýlov, napr.
Neo Plasticismus



Využitie

CBIR- Content based image retrieval (napr. Aj Google)

Optical flow

<http://www.youtube.com/watch?v=ckVQrwYIjAs>

Detekcia predmetov vo videu

<http://www.youtube.com/watch?v=uKI9qyi1wMg&feature=related>

Zmiešaná realita