

Rozpoznávanie planárnych objektov na obraze

Ing. Michal Kottman

Fakulta Informatiky a Informačných Technológií, STU Bratislava

4. marca 2011

Obsah

- 1 Úvod a motivácia
- 2 Detekcia objektov na obraze
 - Hľadanie kľúčových bodov
 - Výpočet lokálneho deskriptora
 - Hľadanie zodpovedajúcich párov deskriptorov
 - Hľadanie planárnych objektov
 - Experiment a výsledky
- 3 Najpoužívanejšie lokálne deskriptory (ak ostane čas)
 - Scale-Invariant Feature Transform (SIFT)
 - Speeded Up Robust Features (SURF)

Prehľad

- 1 Úvod a motivácia
- 2 Detekcia objektov na obraze
 - Hľadanie kľúčových bodov
 - Výpočet lokálneho deskriptora
 - Hľadanie zodpovedajúcich párov deskriptorov
 - Hľadanie planárnych objektov
 - Experiment a výsledky
- 3 Najpoužívanejšie lokálne deskriptory (ak ostane čas)
 - Scale-Invariant Feature Transform (SIFT)
 - Speeded Up Robust Features (SURF)

Lokálne príznaky a deskriptory

Lokálny príznak

Miesto alebo súčasť obrazu so špecifickými vlastnosťami, ktoré možno použiť pri výpočtoch.

Deskriptor

Číselný vektor, ktorý opisuje príznak, pokiaľ možno nemenný voči afinným transformáciám (rotácia, škálovanie, posun).

Lokálne príznaky a deskriptory

Lokálny príznak

Miesto alebo súčasť obrazu so špecifickými vlastnosťami, ktoré možno použiť pri výpočtoch.

Deskriptor

Číselný vektor, ktorý opisuje príznak, pokiaľ možno nemenný voči afinným transformáciám (rotácia, škálovanie, posun).

Využitie deskriptorov

Vyhľadávanie podobných oblastí v dvoch a viacerých obrazoch, najmä v nasledovných oblastiach:

- Vyhľadávanie obrázkov podľa obsahu / podobnosti
- Zarovnávanie obrazov v panorámach
- Sledovanie pohybu vo videu
- Kalibrácia kamery
- 3D rekonštrukcia scény
- *Detekcia a rozpoznávanie známych objektov na obraze*

Prehľad

- 1 Úvod a motivácia
- 2 Detekcia objektov na obraze
 - Hľadanie kľúčových bodov
 - Výpočet lokálneho deskriptora
 - Hľadanie zodpovedajúcich párov deskriptorov
 - Hľadanie planárnych objektov
 - Experiment a výsledky
- 3 Najpoužívanejšie lokálne deskriptory (ak ostane čas)
 - Scale-Invariant Feature Transform (SIFT)
 - Speeded Up Robust Features (SURF)

Hľadanie príznakov / kľúčových bodov

Cieľ - nájsť na obraze kľúčové body, ktoré sú:

- dostatočne odlišné od svojho okolia
- opakovateľne identifikované na rozličných obrazoch
- identifikovateľné aj pri odlišnom osvetlení

Príklad detekcie



Výpočet lokálneho deskriptora

- Využitie algoritmu pre opis lokálnych príznakov (*SIFT*, *SURF*, *BRIEF*, ...), ktoré boli identifikované v prechádzajúcom kroku.
- Výstupom je n-rozmerný vektor, veľkosť závisí od algoritmu:
 - *SIFT*: 128 reálnych čísiel (float)
 - *SURF*: 64 reálnych čísiel (float)
 - *BRIEF*: 64-512 bitov

Výpočet lokálneho deskriptora

- Využitie algoritmu pre opis lokálnych príznakov (*SIFT*, *SURF*, *BRIEF*, ...), ktoré boli identifikované v prechádzajúcom kroku.
- Výstupom je n-rozmerný vektor, veľkosť závisí od algoritmu:
 - *SIFT*: 128 reálnych čísiel (float)
 - *SURF*: 64 reálnych čísiel (float)
 - *BRIEF*: 64-512 bitov

Výsledný vektor je možné použiť viacerými spôsobmi:

- Ako vstup neurónovej siete
- Aplikácia *machine-learning* algoritmov (*PCA*, klastrovanie, ...)
- Hľadanie najbližšieho suseda

Hľadanie zodpovedajúcich párov deskriptorov

Hľadanie párov deskriptorov medzi obrázkami prebieha väčšinou na základe Euklidovskej vzdialenosti medzi vektormi - čím sú “bližšie”, tým sú “podobnejšie”.

$$\forall k_i \in K_1 : l_j = \arg \min_{l \in K_2} |d(k_i) - d(l)| \quad (1)$$

Hľadanie zodpovedajúcich párov deskriptorov

Hľadanie párov deskriptorov medzi obrázkami prebieha väčšinou na základe Euklidovskej vzdialenosti medzi vektormi - čím sú “bližšie”, tým sú “podobnejšie”.

$$\forall k_i \in K_1 : l_j = \arg \min_{l \in K_2} |d(k_i) - d(l)| \quad (1)$$

Techniky:

- *brute-force* - porovnanie všetkých dvojitých deskriptorov medzi obrázkami
- *k-nearest neighbor*, *Approximate Nearest Neighbor* - rýchlejšie vyhľadávanie suseda v n-rozmernom priestore
- pokročilé techniky - *Pyramid Kernel Match*, *Vocabulary Tree*, ...

Vylepšenie výsledkov

- Porovnanie pomeru vzdialenosti $d_1 d_2$ dvoch najbližších susedov, ak $d_1/d_2 > 0.8$, zamietni pár
- Odstránenie všeobecných bodov - vyskytujú sa veľa krát v párovaní

Nájdienie objektu

Pri planárnych objektoch je možné použiť *RANSAC* (RANdom SAMple Consensus) algoritmus pre:

- odfiltrovanie nevhodných párov (outliers)
- nájdienie zobrazenia (homografie) medzi logom a obrazom

Nájdenie objektu

Pri planárnych objektoch je možné použiť *RANSAC* (RANdom SAMple Consensus) algoritmus pre:

- odfiltrovanie nevhodných párov (outliers)
- nájdenie zobrazenia (homografie) medzi logom a obrazom

Ak nájdeme homografiu, chceme povedať že sme našli na obraze hľadaný objekt. Avšak RANSAC nájde homografiu vždy. Preto:

- Rohy objektu podľa spätného zobrazenia musia ležať vnútri obrazu
- Rohy musia tvoriť konvexný obal


Príklad



Experiment

- Dataset pozostáva zo 104 obrázkov
- Homografie sú zadané ručne, pomocou 4 manuálne označených bodov
- Výpočet homografie pomocou uvedeného postupu
 - bez kritérií
 - s kritériami
- Výpočet chyby spätnej projekcie pre obrázky označené ako “logom”
- Výpočet klasifikačnej chyby - koľko obrázkov bolo zle označených ako majúce/nemajúce logo

Výsledky




Prehľad

- 1 Úvod a motivácia
- 2 Detekcia objektov na obraze
 - Hľadanie kľúčových bodov
 - Výpočet lokálneho deskriptora
 - Hľadanie zodpovedajúcich párov deskriptorov
 - Hľadanie planárnych objektov
 - Experiment a výsledky
- 3 Najpoužívanejšie lokálne deskriptory (ak ostane čas)
 - Scale-Invariant Feature Transform (SIFT)
 - Speeded Up Robust Features (SURF)

SIFT - Detekcia príznakov


- 1 zostaví sa obrazová pyramída (škálový priestor) - slúži pre nájdenie kľúčových príznakov rôznych veľkostí
- 2 výpočet DoG pre každý bod:
$$D(x, y, \sigma) = G(x, y, k\sigma) - G(x, y, \sigma) \approx \nabla^2 G(x, y, \sigma)$$
- 3 nájdenie extrém (minimá, maximá) DoG - porovnanie najbližších 8 susedov v priestore aj škále
- 4 výpočet orientácie pomocou gradientu

SIFT - Detekcia príznakov



SIFT - Deskriptor





- Okolie kľúčového bodu je rozdelené na 4×4 častí, pre každú je vypočítaný histogram orientácie gradientu s 8 položkami
- Výsledky sú pre násobené Gaussovou funkciou, normalizované, a výsledných $4 \times 4 \times 8 = 128$ reálnych čísiel je *SIFT deskriptor*



SURF - Detekcia príznakov


Rýchlejší algoritmus ako SIFT, pretože:

- využíva *Haarove vlnky* pre rýchlu aproximáciu funkcie $\nabla^2 G$
- využíva *integrálový obraz* pre ich rýchly výpočet - pre ľubovoľne veľký región stačí poznať 4 hodnoty
- miesto škálovania obrazu - škáluje sa filter



SURF - Deskriptor

- 1 Výpočet orientácie kľúčového bodu
- 2 Okolie je rozdelené na 4×4 časti
- 3 Pre každú časť sa sleduje hodnota Haarovej vlnky na osi X, Y and ich absolútne hodnoty
- 4 Hodnoty sú váhované Gaussovo a normalizované
- 5 Výsledný vektor $4 \times 4 \times 4 = 64$ reálnych čísiel je *SURF deskriptor*



Ďakujem za pozornosť