

Videoanalýza – algoritmy na odčítavanie pozadia

- Čo to je? Sú to metódy na detekciu pohyblivých objektov pomocou statických kamier
- Pohybujúci sa objekt = objekt ktorý sa pohybuje voči „pozadiu“
- Čo je pozadie a čo nie? Potrebujeme spraviť odhad pozadia.
- Potom stačí pozadie odčítať od aktuálneho obrazu a máme obraz pohybujúcich sa objektov
- Jednotlivé snímky videa budeme označovať ako $obr_n(x, y)$, kde $n=1...N$ je pozícia snímky.

Metóda jednoduchkej diferencie [IJCSA2014][PIC2008]

- Založené na jasovej zložke
- aktuálny obrázok je odčítaný od predchádzajúceho
- pre každý pixel je odhadnuté či patrí pozadiu. Pixel $obr_n(x, y)$ pozadiu nepatrí ak
$$|obr_n(x, y) - obr_{n-1}(x, y)| > T_h$$
- T_h je stanovená prahová hodnota

Pozitíva	Negatíva
• nízke výpočtové nároky • nízke pamäťové nároky • extrémne rýchlo sa adaptuje na pozadie (však je aj model pozadia mimoriadne povrchný, je to iba predchádzajúca snímka)	• citlivý na šum • vnútro väčších objektov je často interpretované ako pozadie • veľmi citlivé na threshold

Metóda s detekciou tieňa (r. 1999) [IJCSA2014]

- Vhodné pre RGB video
- Sledujeme 2 druhy rozdielov
 - jasový
 - chromatický
- metóda odlišujem tieň od pohybujúcich sa objektov od samotného objektu
 - pohybujúci objekt má aj jasovú aj chromatickú zložku význačne rozdielnu od pozadia
 - tieň má podobnú chromatickú zložku ako pozadie, ale jasovú má menšiu

Poznámka:

- ako získať lepší model pozadia?
- Pozadie ale nesmie byť statické, musí zohľadňovať (ak je to potrebné)
 - zmeny osvetlenia
 - postupné (deň/noc)
 - náhle (mraky, zapnutie/vypnutie osvetlenia)
 - pohyby
 - chvenie kamery
 - pohyb konárov, trávy, vlny, ...
 - zmeny geometrie pozadia
 - zaparkované pozadia na parkoviskách

Pozadie ako priemer, resp. medián [PIC2008]

Bez selektivity

- pozadie je tvorené ako priemer resp. medián predchádzajúcich K obrázkov
- veľká spotreba pamäti (K obrázkov v pamäti)
- určuje sa pre každý pixel zvlášť (žiadna priestorová korelácia medzi susediacimi pixelmi)

So selektivitou

- každý pixel aktuálneho obrázku je klasifikovaný ako v popredí, alebo ako súčasť pozadia.
- Iba pixely, ktoré sú súčasťou pozadia sa použijú na aktualizáciu modelu pozadia
 - model pozadia je tvorený ako priemer resp. medián pixelov pozadia z predchádzajúcich K obrázkov
 - veľká spotreba pamäti (K obrázkov v pamäti)
 - určuje sa pre každý pixel zvlášť (žiadna priestorová korelácia medzi susediacimi pixelmi)

Pozadie pomocou IIR filtra [PIC2008]

Bez selektivity:

- B_n - je model pozadia pri snímke n
- Aktualizácia modelu pozadia
 - $B_n(x, y) = \alpha obr_n(x, y) + (1 - \alpha)B_{n-1}(x, y)$
- α určuje rýchlosť učenia, typicky 0.05

So selektivitou

- $B_n(x, y) = \begin{cases} \alpha obr_n(x, y) + (1 - \alpha)B_{n-1}(x, y) & \text{ak } obr_n(x, y) \text{ patrí pozadiu} \\ B_{n-1}(x, y) & \text{ak } obr_n(x, y) \text{ nepatrí pozadiu} \end{cases}$

Gaussovské pozadie [PIC2008]



- umožňuje automaticky voliť prah
- okrem priemeru pozadia μ sa modeluje aj rozptyl pozadia σ
 - funguje iba pre unimodálne rozdelenie jasu pozadia v histograme (jeden význačný vrchol)
- $\mu_n(x, y) = \alpha obr_n(x, y) + (1 - \alpha)\mu_{n-1}(x, y)$
- $\sigma_n^2(x, y) = \alpha [obr_n(x, y) - \mu_n(x, y)]^2 + (1 - \alpha)\sigma_{n-1}^2(x, y)$
- pri teste sa testuje, či $|obr_n(x, y) - \mu_{n-1}(x, y)| > T_h$, pričom $T_h = k\sigma$

Pozadie ako gaussovský mix [PIC2008] [GM] [GM_FG]

- ak na pozadí sa mení pomaly iba osvetlenie, potom stačí 1 mód aby sa eliminoval šum prítomný z procesu snímania
- čo ak sú ale prítomné, napr. pravidelné odlesky (napr. od vodnej hladiny), vypnuté/zapnuté osvetlenie, blikanie monitora
- multimodálne rozdelenie (3-5 módov)
- mód i je chrakterizovaný tripletom $(\mu_i, \sigma_i, \omega_i)$, kde ω_i je váha
- μ_i, σ_i sú aktualizované ako pri 1 gaussovskom pozadí
- ω_i sú aktualizované pri každom novom obrázku videa
- či pixel patrí nejakému módu je zisťované pomocou $T_h = 2.5\sigma_i$

Poznámky:

- Podobne ako pozadie, môže byť aj popredie modelované ďalšími módm



Príklda: Bimodalita prítomná v jase jedného pixelu v priebehu času. Spôsobené blikaním monitora.

Poznámka: jasne vidíme a môžeme kvantifikovať „neviditeľné veci v obraze“

Priestorová korelácia

- Doteraz sme hovorili iba o modeli v čase, každý pixel mal vlastný model, nezávislý od modelov ostatných pixelov
- Toto dáva veľký priestor náhodným chybám
- Náhodné chyby sa dajú do veľkej miery eliminovať, keď blízke body zkorelujeme - spravíme ich závislými, napr. DP filtráciou (toto sme robli aj pri matlab deme)
 - stratíme na citlivosti
 - získame na robustnosti

Počítačové videnie (computer vision)

- Ciele, napr.
 - Detekcia objektov v obraze (**objekt**=oblasť v obraze, ktorá sa niečím vyznačuje, špecifickými príznakmi)
 - Popis/Identifikácia objektov v obraze
- Jedným zo základov je analýza príznakov v obraze (**predspracovanie, extrakcia, výber/redukcia, klasifikácia**)
 - Príznačky kvantifikujú nejaké vlastnosti obrazu/objektu
 - Nízkoúrovňové príznaky (základné vlastnosti objektov – tvar, farba, textúra, hrany, rohy, ...)
 - Bodové (opisujú jednotlivé body pozíciou, intenzitou, farbou, ...)
 - Globálne (opisujú celý obraz, alebo časti (objekty) vzniknuté segmentáciou (rozdelenie obrazu na segmenty, opisujú napr. pomocou farby, textúry, tvaru ...)
 - Lokálne
 - Strednoúrovňové príznaky (spájajú nízkoúrovňové príznaky a idú do sémantických kategórií – napr. voda, sneh, skala, tvár, postava, ...)
 - Vysokoúrovňové príznaky (sémantika /popis celej scény - napríklad osoba sediaca na pláži)
 - príznaky sa spájajú do vektorov -> **vektor príznakov**
 - objekt sa vyznačuje nejakým vektorom príznakov (**deskriptor objektu**)
 - dva rovnaké objekty musia mať rovnaké deskriptory a naopak, dva rovnaké deskriptory musia opisovať rovnaké objekty,
 - podobné objekty musia byť klasifikovateľné do jednej triedy, ak majú podobné (blízke) deskriptory,
 - príznaky by mali byť invariantné. Najmä voči geometrickým transformáciám ak máme rozpoznať objekty snímané z rôznych zorných uhlov,
 - deskriptor by mal byť kompaktný. Mal by obsahovať najmenšiu množinu informácií, ktorá je potrebná na identifikáciu daného objektu a jeho odlíšenie od objektov iných tried.

Príklad – príznaky tvaru

- **obvod** - napr. ak máme objekt popísaný reťazovým kódom („osemsmerák“), ľahko vypočítame obvod objektu
- **priemerná energia zakrivenia** – množstvo energie potrebné na transformáciu uzavretej krovky na kruh s rovnakým obvodom
 - definovaná pomocou krivosti v jednotlivých bodoch obvodu
 - krivosť krivky = prevrátená hodnota polomeru vpísanej kružnice
- **obsah** – zrejme ...
- **priemer** – max. vzdialenosť medzi bodmi objektu
- **hlavná os** – smer v ktorom je stanovený priemer
- **vedľajšia os** – kolmá na hlavnú os
- **signatúra** - 1D signál opisujúci 2D krivku, napr. vzdialenosť bodov obvodu od ťažiska
- ...



A takto by sme mohli pokračovať celým panteónom priznakov

SW základ pre počítačové videnie

- Matlab – súčasť výučby (najlepšie prepojenie), proof of concept (PoC)
 - computer vision toolbox
 - matlab vie volať openCV funkcie pomocou interfejsových knižníc
- openCV (java, python, C/C++ API) – reálne, životaschopné projekty

Expertná videoanalýza

- nesnažiť sa napodobiť ľudské oči, ale im trochu „pomôcť“
- využitie obrovského množstva údajov vo viditeľnom spektre
- chceme vidieť „neviditeľné“ zachytenie a štatistické spracovanie jemných detailov (a ich prípadné následné zvýraznenie v pôvodnom videu (ideálne v reálnom čase)) napr.
 - pulz krvi v žilách
 - trasenie rúk (diagnostika napr. parkinsonovej choroby)
 - detektor lži (nie posudzovanie, len zvýrazňovanie príznakov)
 - ...
- klasické
 - meranie vzdialeností