



Univerza v Ljubljani
Fakulteta za *elektrotehniko*

Sledenje in analiza gibanja


Stanislav Kovačič



<http://vision.fe.uni-lj.si/>



Samostojno vozilo



Ernst Dickmanns, Universität der Bundeswehr München,
več kot 20 let raziskovanja na področju dinamičnega vida




Področja uporabe

- Prometni sistemi (*Angl. Transportation systems*)
 - na primer nadzor prometa, upravljanje vozila, pomoč vozniku,
- Nadzorni (varnostni) sistemi (*Angl. Surveillance systems*)
 - na primer tehnično varovanje zgradb, oseb, obramba,
- Uporabniški vmesniki (*MMI-Man Machine Interfaces, ali HCI*)
 - na primer interakcija z gibi, gestami, ...
- Zabavna industrija
 - filmska industrija, multimedia
- Šport
 - sledenje, analiza obremenitev igralcev, trening, športni prenosi, ...



Podpora vozniku



D. M. Gavrila, DaimlerChrysler Research, Ulm, Germany, 1999-
Primerjanje s predlogo in 'distančni transform', od grobega k finejšemu.



Nadzor prometa



J. Malik et al., Computer Vision Group, University of California, Berkeley, ~ 1996



Obramba

Brnik, 2007



Nadzorni (varnostni) sistemi



D. Hogg, School of Computing, University of Leeds, UK, ~ 1998.



FLIR

Ljubljana, 2007





Uporabniški vmesniki



D. Gorodnichy, Computational Video Group
National Research Council of Canada.



G. Bradsky, Willow Garage,
Stanford University



Iz vsebine

- Splošno o vizualnem sledenju in analizi gibanja
- Čas do dotika
- Optični tok
- Vizualno sledenje in Kalmanov filter



Športni dogodki



LSV, UL FE, 1998-2012



Analiza gibanja

- V računalniškem vidu skušamo na podlagi zaporedja slik iz ene (ali več) kamer sklepati na gibanje objektov v prostoru.
 - Slika se kot posledica gibanja objektov v prostoru s časom spreminja in
 - z analizo teh sprememb skušamo sklepati na gibanje objektov.
- Op.:
 - Stacionarna kamera, gibljiv prizor
 - Gibljiva kamera, stacionaren prizor
 - Gibljiva kamera, gibljiv prizor



Analiza gibanja - stereo vid

- Problematika analize gibanja (zaporedja slik) ima precej skupnega s stereo vidom.
- V obeh primerih gre za iskanje korespondence med dvema podobnima slikama.
- V primeru časovnega zaporedja slik je ta razlika običajno majhna - primerjanje je manj zahtevno.
- So pa disparitete slik bolj svobodne.



Nekateri izrazi

- Detekcija (zaznavanje) gibanja/premika (Angl. *Motion Detection*) ali se je objekt zanimanja premaknil
- Sledenje objektov (Angl. *(Object/Target) Tracking*) kje se objekt zanimanja nahaja v zaporedju slik
- Analiza (kvalitativna, kvantitativna) (Angl. *Motion Analysis*) kaj se z objektom zanimanja dogaja
- Razpoznavanje (Angl. *Motion Recognition*) kaj gibanje objekta je
- Razumevanje (Angl. *Motion Understanding*) kakšen je pomen gibanja




Pristopi

- Diferenčne metode
 - Odštevanje ozadja
 - Odštevanje (zaporednih) slik
 - Utežena kombinacija obeh
 - Optični tok (in polje gibanja)
- Primerjalne metode (podobno kot stereo)
 - Primerjanje - sledenje področij
 - Primerjanje - sledenje značilnih točk
 - Prilagodljivi (deformabilni) (aktivni) modeli ('kače')
- Kalmanov filter, filtri z delci
 - Ocena novega položaja na osnovi preteklosti



Čas do "dotika"

- Gibljivi vizualni vzorci vsebujejo veliko količino informacije.
- Že samo na podlagi *slike* se da ugotoviti čas do dotika (trčenja) (Angl. *Time to Impact, Time to Collision*).



$$\tau = \frac{x(t)}{\dot{x}(t)}$$

Iz trenutne pozicije točke v sliki in spremembe pozicije (odvoda) se da brez poznavanja velikosti objekta ali razdalje do objekta ali hitrosti objekta oceniti čas do „dotika“

Čas do "dotika"

Slikovna ravnina

$Z = Z_0 - v \cdot t = 0 \Rightarrow \tau = \frac{Z_0}{v}$ To velja za vsak (začetni) trenutek

$\frac{x(t)}{f} = \frac{X}{Z(t)} \Rightarrow x(t) = f \frac{X}{Z(t)}$

$\dot{x}(t) = -f \frac{X}{Z^2(t)} \dot{Z}(t) = x(t) \frac{v}{Z(t)} \Rightarrow \frac{\dot{x}(t)}{x(t)} = \frac{v}{Z(t)} \Rightarrow \tau = \frac{x(t)}{\dot{x}(t)}$

Polje gibanja

$$\dot{\mathbf{P}} = \mathbf{V} = \begin{bmatrix} V_x \\ V_y \\ V_z \end{bmatrix} = -\mathbf{T} - \boldsymbol{\omega} \times \mathbf{P} = \begin{bmatrix} -T_x - \omega_y \times Z + \omega_z \times Y \\ -T_y - \omega_z \times X + \omega_x \times Z \\ -T_z - \omega_x \times Y + \omega_y \times X \end{bmatrix}$$

$$\dot{\mathbf{p}} = \mathbf{v} = f \frac{\mathbf{Z} \cdot \mathbf{V} - V_z \cdot \mathbf{P}}{Z^2}$$

$$v_x = \frac{T_z x - T_x f}{Z} - \omega_y f + \omega_z y + \frac{\omega_x x y}{f} - \frac{\omega_y x^2}{f}$$

$$v_y = \frac{T_z y - T_y f}{Z} + \omega_x f - \omega_z x - \frac{\omega_y x y}{f} + \frac{\omega_x y^2}{f}$$

translatorni del rotacijski del (neodvisen od razdalje - Z)

Polje gibanja

- Polje gibanja (angl. Motion Field) je 2D upodobitev polja (vektorjev) hitrosti gibanja (Angl. Velocity Field) v prizoru.

3D vektor hitrosti $\mathbf{V} = -\mathbf{T} - \boldsymbol{\omega} \times \mathbf{P}$, $\mathbf{p} = f \frac{\mathbf{P}}{Z}$, $\dot{\mathbf{p}} = \mathbf{v} = f \frac{\mathbf{Z} \cdot \mathbf{V} - V_z \cdot \mathbf{P}}{Z^2}$ Točka v prostoru

Translatorna hitrost Kotna hitrost Točka v sliki 2D vektor gibanja $\mathbf{v} = \begin{bmatrix} v_x \\ v_y \\ 0 \end{bmatrix} = \begin{bmatrix} v_x \\ v_y \end{bmatrix}$

Polje gibanja: translacija

- $v_x = \frac{T_z x - T_x f}{Z}$
 $v_y = \frac{T_z y - T_y f}{Z}$ Poljubna „čista“ 3D translacija brez rotacije
- $v_x = -\frac{T_x f}{Z} = -f \frac{T_x}{Z}$
 $v_y = -\frac{T_y f}{Z} = -f \frac{T_y}{Z}$ $T_z = 0$; Vektorji polja gibanja so vzporedni
- $v_x = \frac{T_z x - T_x f}{Z} = \frac{T_z}{Z} (x - f \frac{T_x}{T_z}) = \frac{T_z}{Z} (x - x_0)$ Radialno polje gibanja (x_0, y_0) središče širjenja/krčenja (gibanje v „globino“)



Optični tok (angl. Optical Flow)


- Časovne spremembe svetlosti slike imenujemo 'optični tok' (Angl. Optical Flow).
 - Na podlagi optičnega toka skušamo sklepati na polje gibanja - gibanje objektov.
 - Optični tok pove veliko o polju gibanja in polju hitrosti.
 - Vendar so svetlostne spremembe v sliki posledica tudi drugih učinkov, ne le gibanja.



Optični tok - problem reže

- Koliko nam enačba optičnega toka pove o polju gibanja?

$$\begin{bmatrix} \nabla_x E & \nabla_y E \end{bmatrix} \begin{bmatrix} v_x \\ v_y \end{bmatrix} = -E_t \quad \text{Ena enačba, dve neznanki}$$



- Določiti se da samo komponento hitrosti v smeri svetlostnega gradienta
- Pojav je znan kot 'problem reže' (angl. Aperture problem).



Enačba optičnega toka

$$E(x + \Delta x, y + \Delta y, t + \Delta t) = E(x, y, t)$$

$$E(x, y, t) + \frac{\partial E}{\partial x} \Delta x + \frac{\partial E}{\partial y} \Delta y + \frac{\partial E}{\partial t} \Delta t + O = E(x, y, t)$$

$$\frac{\partial E}{\partial x} \Delta x + \frac{\partial E}{\partial y} \Delta y + \frac{\partial E}{\partial t} \Delta t + O = 0$$


$$\frac{\partial E}{\partial x} \frac{\Delta x}{\Delta t} + \frac{\partial E}{\partial y} \frac{\Delta y}{\Delta t} + \frac{\partial E}{\partial t} + O = 0$$

$$E_x \dot{x} + E_y \dot{y} = -E_t$$

$$(\nabla E)^T v = -E_t$$

Svetlostni gradient

Časovna sprememba svetlosti



Optični tok

- Računanje optičnega toka je zelo občutljivo na šum.
- Priporočljivo je (predhodno) filtriranje z nizkopasovnim (na primer Gaussovimi) filtrom.
- Lahko pa operacijo filtriranja in odvajanja kar združimo, t.j. filtriramo z odvodom Gausa.

$$E' = (G * E)' = G' * E$$

- Smiselna je tudi naslednja predpostavka: polje gibanja se počasi spreminja (je konstantno v majhni okolici izbrane točke).
- Torej lahko za vse točke (slikovne elemente) v majhni okolici določimo skupen (povprečen) vektor polja gibanja.



Optični tok

- Za vsako točko p_i v majhni okolici, t.j. 'oknu' velikosti $N \times N$ lahko zapišemo:

$$(\nabla E^{(i)})^T v + E^{(i)}_t = 0$$

- Iščemo v , ki minimizira srednje kvadratno odstopanje:

$$e(v) = \sum_{p_i} \left[(\nabla E^{(i)})^T v + E^{(i)}_t \right]^2$$

- Za vsako točko v oknu izračunamo svetlostni gradient in časovni odvod ter izračunamo optimalni v .
- To naredimo za vse točke v sliki ?



Še o optičnem toku

'Detektor oglišč'

$$A^T A = \begin{bmatrix} \sum E_x^2 & \sum E_x E_y \\ \sum E_x E_y & \sum E_y^2 \end{bmatrix}$$

$$A^T A = M \Lambda M^T = M \begin{bmatrix} \lambda_1 & 0 \\ 0 & \lambda_2 \end{bmatrix} M^T$$

- 'Dobre' sledilne točke so tiste z velikima lastnima vrednostima.



Optični tok


- Minimizacija $e(v) = \sum_{p_i} \left[(\nabla E(p_i))^T v + E(p_i)_t \right]^2$

pomeni rešiti normalno enačbo $A^T A v = A^T b$

$$A = \begin{bmatrix} \nabla E(p_1)^T \\ \nabla E(p_2)^T \\ \vdots \\ \nabla E(p_{N \times N})^T \end{bmatrix} \quad b = \begin{bmatrix} E_t(p_1) \\ E_t(p_2) \\ \vdots \\ E_t(p_{N \times N}) \end{bmatrix}$$



Optični tok - primer



J. Perš, LST, FE, UNI-LJ, 2003.




Optični tok - polje gibanja

- Optični tok je dobra aproksimacija polja gibanja:
 - v primeru Lambertovih površin,
 - majhnih fotometričnih distorzij,
 - oddaljenega točkastega svetila,
 - na mestih z velikim svetlostnim gradientom.



Primerjalni pristopi

- Detekcija „dobrih“ sledilnih točk
Najprej v vseh slikah (parih slik) detektiraj „zanimive“ točke
Predstavi te točke z opisniki (deskriptorji), na primer SIFT
Išči korespondence točk v zaporedju slik




Op.: zgolj kot ilustrativni primer

- Ugotovitev:
Ne upoštevajo značilnosti („dinamike“) gibanja.



Primerjalni pristopi

- Korelacijski pristopi
Za vsako točko/področje ali samo za izbrane točke/področja slike v trenutku t_k primerjaj njeno okolico S_1 s potencialno korespondenčnimi področji naslednje slike S_2 v trenutku t_{k+1} .



Kalmanov filter (R.E.Kalman 1960)

- Kalmanov filter je osnovno orodje, ki se na področju računalniškega vida uporablja za sledenje objektov v povezavi z najrazličnejšimi drugimi pristopi.
- Kalmanov filter s stališča sledenja pomaga oceniti nov položaj gibajočega se objekta (značilne točke) in negotovost položaja,
 - to je napove kje iskati objekt v naslednji sliki in
 - kolikšno naj bo področje iskanja (pregledovanja).
- Rešuje probleme v zvezi z
 - manjkajočo informacijo,
 - nepopolno informacijo,
 - moteno informacijo.



Sledenje - Kalman - osnove

Zanima nas položaj (in hitrost) poljubne (izbrane) slikovne točke skozi čas, torej trajektorija točke skozi zaporedje slik.

$$\mathbf{p}_k = \begin{bmatrix} x_k \\ y_k \end{bmatrix} \quad \text{Položaj (značilne) slikovne točke v diskretnem trenutku-sliki } k$$

$$\mathbf{v}_k = \begin{bmatrix} v_{x,k} \\ v_{y,k} \end{bmatrix} \quad \text{Hitrost slikovne točke v diskretnem trenutku } k$$

$$\mathbf{x}_k = \begin{bmatrix} \mathbf{p}_k \\ \mathbf{v}_k \end{bmatrix} = \begin{bmatrix} x_k \\ y_k \\ v_{x,k} \\ v_{y,k} \end{bmatrix} \quad \text{Vektor „stanja“ (položaj in hitrost) v trenutku } k$$



Sledenje - Kalman - osnove

Predpostavljamo, da merimo položaj točke v časovnih trenutkih k . Izmerjena vrednost je odvisna od stanja sistema in je motena s šumom.

$$\mathbf{z}_k = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} \mathbf{p}_k \\ \mathbf{v}_k \end{bmatrix} + \boldsymbol{\mu}_k \quad \boldsymbol{\mu}_k \sim N(0, \mathbf{R}_k)$$

$$\mathbf{z}_k = \mathbf{H}\mathbf{x}_k + \boldsymbol{\mu}_k$$

Merilna matrika

Meritev

Gaussov beli šum
„merilni šum“
Srednja vrednost nič
Kovarianca \mathbf{R}

$$\begin{aligned} \mathbf{x}_k &= \mathbf{A}\mathbf{x}_{k-1} + \mathbf{w}_{k-1} \\ \mathbf{z}_k &= \mathbf{H}\mathbf{x}_k + \boldsymbol{\mu}_k \end{aligned}$$



Sledenje - Kalman - osnove

Preprost linearni model konstantne hitrosti

$$\mathbf{p}_k = \mathbf{p}_{k-1} + \mathbf{v}_{k-1} + \boldsymbol{\xi}_{k-1} \quad \text{Prehod na nov položaj ni čisto tak, zato } \boldsymbol{\xi}$$

$$\mathbf{v}_k = \mathbf{v}_{k-1} + \boldsymbol{\eta}_{k-1} \quad \text{Hitrost ni čisto konstantna, zato } \boldsymbol{\eta}$$

$$\mathbf{x}_k = \mathbf{A}\mathbf{x}_{k-1} + \mathbf{w}_{k-1} \quad \mathbf{w}_k = \begin{bmatrix} \boldsymbol{\xi}_k \\ \boldsymbol{\eta}_k \end{bmatrix}, \quad \mathbf{w}_k \sim N(0, \mathbf{Q}_k)$$

Enačba

prehajanja

stanj

$$\mathbf{A} = \begin{bmatrix} 1 & 0 & 1 & 0 \\ 0 & 1 & 0 & 1 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$$

Sistemska
matrika

Gaussov beli šum
„sistemski šum“
Srednja vrednost nič
Kovarianca \mathbf{Q}



Sledenje - ogrodje algoritma

Ponavljamo za $k=1,2,3,\dots$

Imamo začetno/trenutno oceno pozicije in hitrosti $\hat{\mathbf{x}}_{k-1}$

Izračunamo novo oceno pozicije in hitrosti $\hat{\mathbf{x}}_k^- = \mathbf{A}\hat{\mathbf{x}}_{k-1}$

Izmerimo novo pozicijo \mathbf{z}_k

Izračunamo razliko $\mathbf{r}_k = \mathbf{z}_k - \mathbf{H}\hat{\mathbf{x}}_k^-$

Posodobimo stanje $\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k \mathbf{r}_k$

Vprašanja:

Kako določimo ojačenje \mathbf{K} ?

Če bolj verjamemo meritvi, je \mathbf{K} večji, sicer manjši (ali nič)

Kako dobra je ocena (negotovost) stanja \mathbf{x} ?

Na negotovost vplivata negotovost meritve in sistema

Kalman daje odgovor na ta vprašanja na sistematičen način in na trdnih teoretičnih podlagah.

Kalmanov filter (1960)

Matrika prehajanja stanj – sistemska matrika

Vhodna matrika

Vektor stanja

Vektor vhodov, lahko 0

Sistemiški šum
Gaussov beli šum

Vektor meritev

Merilna matrika

Merilni šum
Gaussov beli šum

$$\mathbf{x}_k = \mathbf{A}_{k-1} \mathbf{x}_{k-1} + \mathbf{B}_k \mathbf{u}_k + \mathbf{w}_{k-1}$$

$$\mathbf{z}_k = \mathbf{H}_k \mathbf{x}_k + \mathbf{v}_k$$

$$\mathbf{w}_k \sim N(\mathbf{0}, \mathbf{Q}_k)$$

$$\mathbf{v}_k \sim N(\mathbf{0}, \mathbf{R}_k)$$

$k = 0, 1, 2, \dots$; diskretni časovni trenutki
V splošnem se matrike (in šum) lahko spreminjajo, največkrat pa se ne

Kalmanov filter

Optimalno „ojačenje“ oz optimalno „tehtanje“ med meritvijo in napovedjo.

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{z}_k - \mathbf{H} \hat{\mathbf{x}}_k^-)$$

$$\mathbf{K}_k = \mathbf{P}_k^- \mathbf{H}^T (\mathbf{H} \mathbf{P}_k^- \mathbf{H}^T + \mathbf{R})^{-1} = \frac{\mathbf{P}_k^- \mathbf{H}^T}{\mathbf{H} \mathbf{P}_k^- \mathbf{H}^T + \mathbf{R}}$$

Čim manjši je R, bolj kakovostna je meritev, večji je K, bolj upoštevamo meritve.

Čim večji je R, večja je negotovost meritve, manjši je K, manj zaupamo in torej manj upoštevamo meritve.

$$\mathbf{P}_k = E[\mathbf{e}_k \mathbf{e}_k^T] = E[(\mathbf{x}_k - \hat{\mathbf{x}}_k)(\mathbf{x}_k - \hat{\mathbf{x}}_k)^T]$$
 Kovarianca ocene stanja

Kalmanov filter

$\hat{\mathbf{x}}_k$ a posteriori ocena stanja po meritvi v trenutku k, $\hat{\mathbf{x}}_k = E(\mathbf{x}_k)$

$\hat{\mathbf{x}}_k^-$ a priori ocena stanja tik pred meritvijo v trenutku k

$\mathbf{e}_k^- = \mathbf{x}_k - \hat{\mathbf{x}}_k^-$ napaka a priori ocene

$\mathbf{e}_k = \mathbf{x}_k - \hat{\mathbf{x}}_k$ napaka a posteriori ocene, $E(\mathbf{e}_k) = 0$

$\mathbf{P}_k^- = E[\mathbf{e}_k^- \mathbf{e}_k^{-T}]$ kovarianca napake a priori ocene

$\mathbf{P}_k = E[\mathbf{e}_k \mathbf{e}_k^T]$ kovarianca napake a posteriori ocene

„ojačenje“

Napovedani rezultat meritve

$$\hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}(\mathbf{z}_k - \mathbf{H}\hat{\mathbf{x}}_k^-)$$

Merilna posodobitev

Kalmanov filter - algoritem

Predikcija

$$(1) \hat{\mathbf{x}}_k^- = \mathbf{A} \hat{\mathbf{x}}_{k-1} + \mathbf{B} \mathbf{u}_k$$

$$(2) \mathbf{P}_k^- = \mathbf{A} \mathbf{P}_{k-1} \mathbf{A}^T + \mathbf{Q}$$

Korekcija

$$(1) \mathbf{K}_k = \frac{\mathbf{P}_k^- \mathbf{H}^T}{\mathbf{H} \mathbf{P}_k^- \mathbf{H}^T + \mathbf{R}}$$

$$(2) \hat{\mathbf{x}}_k = \hat{\mathbf{x}}_k^- + \mathbf{K}_k (\mathbf{z}_k - \mathbf{H} \hat{\mathbf{x}}_k^-)$$

$$(3) \mathbf{P}_k = (\mathbf{I} - \mathbf{K}_k) \mathbf{P}_k^- (\mathbf{I} - \mathbf{K}_k)^T + \mathbf{K}_k \mathbf{R} \mathbf{K}_k^T$$

začetni vrednosti \mathbf{P}_{k-1} in $\hat{\mathbf{x}}_{k-1}$

Kalman filter: „na delu“

The figure illustrates the Kalman filter process in three stages: prediction, measure, and update. Each stage is accompanied by a small image and a corresponding probability density function (PDF) plot.

- prediction:** The top-left image shows a branch with a blue circle indicating a predicted position. The PDF plot below it shows a single peak at the predicted position. The equation is $p(x_t|y_{1:t-1}) = p(x_t|x_{t-1})p(x_{t-1}|y_{1:t-1})$.
- measure:** The top-middle image shows the same branch with a red circle indicating a measured position. The PDF plot below it shows a single peak at the measured position. The equation is $p(y_t|x_t)$.
- update:** The top-right image shows the branch with a green circle indicating the updated position. The PDF plot below it shows a single peak at the updated position. The equation is $p(x_t|x_{t-1}) \propto p(y_t|x_t)p(x_t|y_{1:t-1})$.

M.Kristan

Povzetek

- Polje hitrosti, polje gibanja, optični tok
- Čas do dotika
- Optični tok
- Sledenje, Kalman

Kalmanov filter - omejitve

- Linearen model procesa
- Gaussov merilni in sistemski šum
- Rešitve
 - Razširjen Kalmanov filter – EKF, UKF
 - Filtri z delci („particle filters“)

Viri

Trucco, Verri, Intrudutory techniques for 3D CV, Prentice-Hall, 1998.

Welch, Bishop, An Introduction to the Kalman filter, Siggraph 2011.

Sorenson, LS Estimation, from Gauss to Kalman, Ieee Spectrum, 1970.