



# Sisteme de Vedere Artificială

## Urmărirea formelor

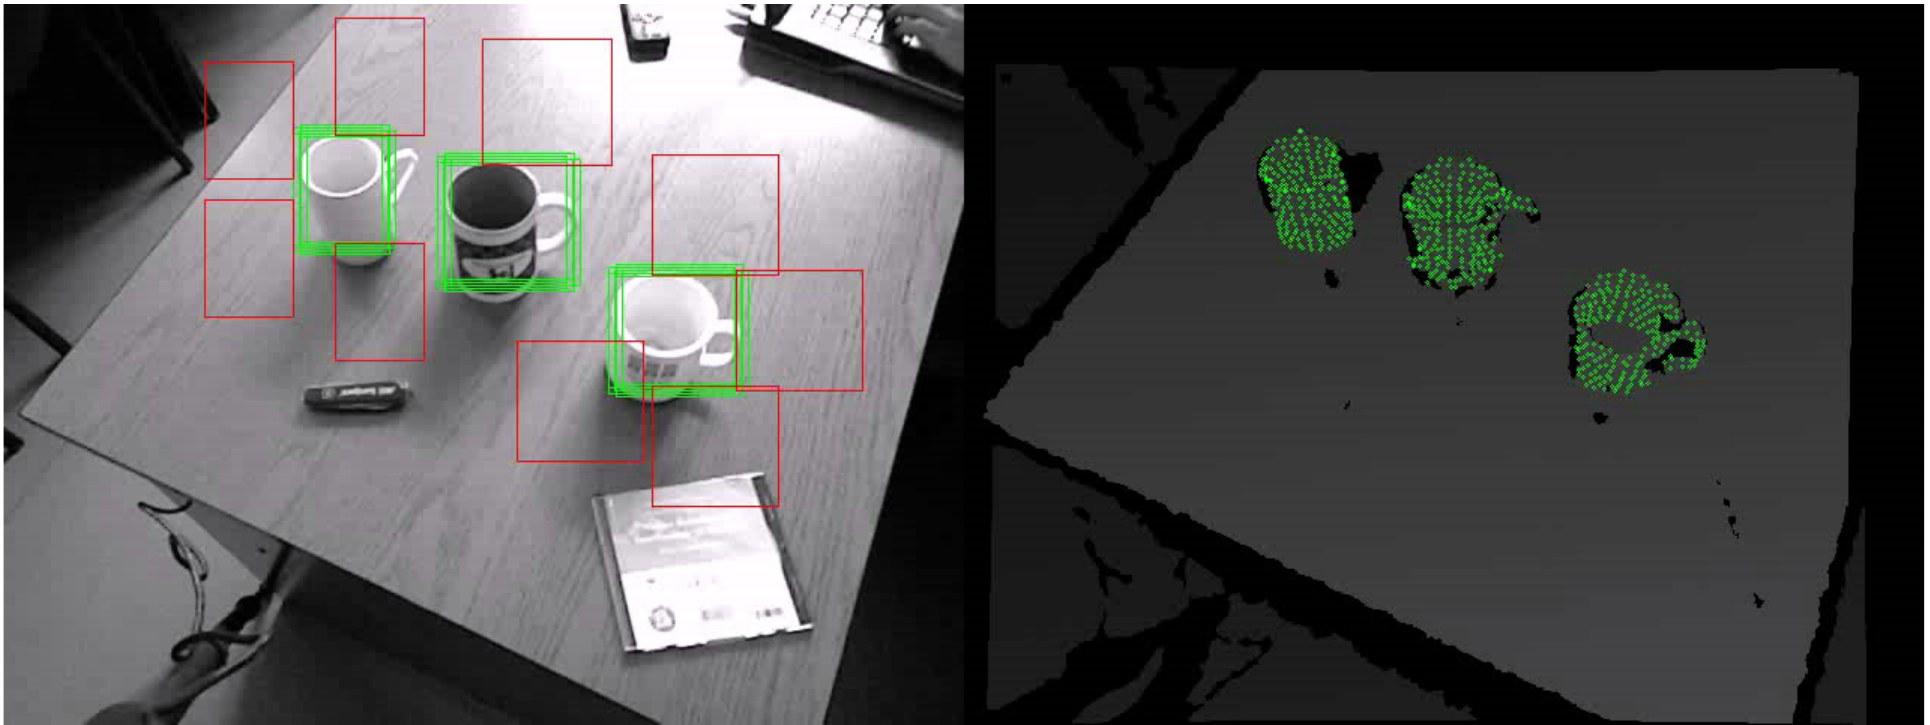
Sorin M. Grigorescu



# Cuprins

- Fluxul optic
- Modele dinamice în urmărirea formelor

# Exemplu





## **Urmărirea formelor: definiții**




## Definiții

- Într-un mare număr de aplicații, informațiile de intrare ce trebuie procesate sunt formate din secvențe video și nu din imagini singulare.
- În acest caz, obiectivul sistemului de vedere artificială este de a urmări mișcarea obiectului (sau a obiectelor) în secvența de imagini video.
- Această operație este compusă din două componente principale: *măsurarea și modelare.*

# Mișcarea și organizarea datelor




- Chiar și dintr-un număr redus de date, se pot extrage informații relevante



# Mișcarea și organizarea datelor




- Chiar și dintr-un număr redus de date, se pot extrage informații relevante





# Reprezentarea datelor

- O secvență video este reprezentată de un număr de imagini achiziționate de-a lungul unei perioade de timp.
- Informația vizuală este reprezentată de date spațiale  $(x,y)$  și timp  $t$ .






# Aplicații

- Analiza traficului pe autostrăzi
- Numărarea persoanelor (în metrou)
- Analiza testelor de accident (crash tests)
- Detecția traiectoriei pietonilor în sistemele de asistență auto
- Etc.



# Câmp de mișcare


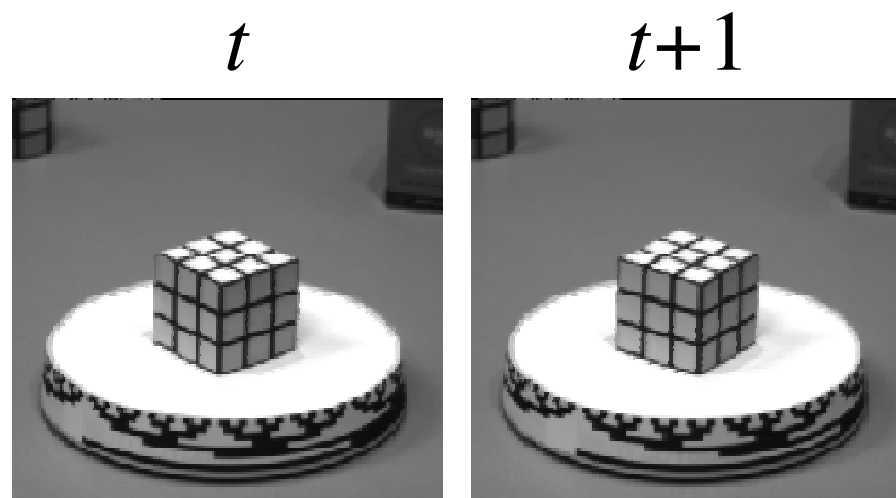
- ***Câmpul de mișcare*** reprezintă deplasarea relativă într-o scenă, sau secvență video, a obiectelor, suprafețelor și cantelor, cauzată de mișcarea relativă dintre un observator (cameră) și scena vizualizată.
- **Direcția și intensitatea (magnitudinea) fluxului optic la orice locație sunt indicate de direcția și lungimea fiecărui vector.**





# Câmp de mișcare

- Câmpul de mișcare reprezintă proiecția mișcării 3D în imagine






# Câmp de mișcare

- $P(t)$  este un punct 3D în mișcare
- Viteza unui punct  $V = \frac{dP}{dt}$
- $p(t) = [x(t), y(t)]$  reprezintă proiecția lui  $P$  în imagine
- Viteza relativă  $v$  în imagine dată de componentele

$$v_x = \frac{dx}{dt} \quad v_y = \frac{dy}{dt}$$

- $v_x$  și  $v_y$  reprezintă **câmpul de mișcare** în imagine



$$D(f/g) = (g f' - g' f)/g^2$$



## Câmp de mișcare


$$V = (V_x, V_y, V_z) \quad p = f \frac{P}{Z}$$

- Pentru a determina viteza  $v$ , se calculează derivata lui  $p$  față de  $t$

$$v = f \frac{ZV - V_z P}{Z^2}$$


$$v_x = \frac{fV_x - V_z x}{Z} \quad v_y = \frac{fV_y - V_z y}{Z}$$

- Mișcarea în imagine este o funcție dependentă de mișcarea 3D ( $V$ ), și de distanța 3D ( $Z$ ) față de cameră





# Câmp de mișcare + mișcarea camerei




Lungimea vectorilor  
este invers  
proporțională cu  
distanța  $Z$  a punctelor  
3D

Punctele apropiate de cameră se  
deplasează mai rapid în planul  
imaginii

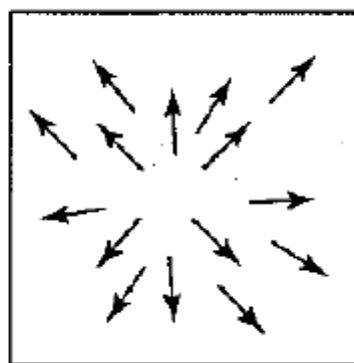
Figure 1.2: Two images taken from a helicopter flying through a canyon and the computed optical flow field.




# Câmp de mișcare + mișcarea camerei



**Zoom out**



**Zoom in**



**Translație către dreapta**



# Fluxul optic

- ***Fluxul optic*** reprezintă mișcarea aparentă a regiunilor de o anumită intensitate luminoasă în imagine.
- Ideal, fluxul optic ar trebui să fie identic câmpului de mișcare.
- Pot apărea mișcări aparente de intensitate chiar și când câmpul de mișcare este zero:




# Fluxul optic


- ***Fluxul optic*** reprezintă mișcarea aparentă a regiunilor de o anumită intensitate luminoasă în imagine.
- Ideal, fluxul optic ar trebui să fie identic câmpului de mișcare.
- Pot apărea mișcări aparente de intensitate chiar și când câmpul de mișcare este zero:
  - Atunci când obiectul și camera rămân nemișcate, dar sursa luminoasă se deplasează



# Estimarea fluxului optic




$I(x,y,t-1)$



$I(x,y,t)$

- Estimarea câmpului de mișcare din două imagini.
- Presupuneri:
  - Intensitatea luminoasă este similară în ambele cadre (același punct din  $t-1$  este similar cu cel din  $t$ )
  - Deplasare mică (punctele nu se deplasează mult)
  - Consistență spațială (punctele se deplasează asemenea vecinilor) <sup>18</sup>

# Ecuția intensității luminoase constante



$$I(x, y, t - 1) = I(x + u(x, y), y + v(x, y), t)$$

$$I(x, y, t - 1) \approx I(x, y, t) + I_x \cdot u(x, y) + I_y \cdot v(x, y)$$

$$I_x \cdot u + I_y \cdot v + I_t \approx 0$$

$$I_x = \frac{\partial I}{\partial x}$$



# Modele dinamice în urmărirea formelor




# Detecție vs. Tracking

- **Detecția:** Obiectul în mișcare este detectat independent în fiecare imagine, iar poziția sa este înregistrată.



- **Tracking** (încorporând *dinamică*): Obiectul în mișcare este detectat, iar poziția sa determinată; Dinamica este încorporată pentru a prezice următoarea poziție a obiectului.





# Dinamica

- Dinamica, în urmărirea formelor, utilizează un model al mișcării obiectului pentru a **prezice** unde se va afla acesta în cadrul următor (înaintea achiziției imaginii)





# Dinamica



## ▪ Avantaje:

- **Detecția obiectului este restricționată la anumite zone ale imaginii;**
- **Estimatele poziției sunt îmbunătățite prin modelarea zgomotului (erori de măsurare) în modelul dinamic.**

## ▪ Presupuneri:

- **Camera nu se deplasează instant într-o nouă poziție;**
- **Obiectele nu dispar și/sau reapar în imagini;**
- **Obiectul și/sau camera se deplasează gradual.**



# Urmărirea formelor prin inferență


- **Starea ascunsă**  $X$  este reprezentată de parametrii de interes (poziția obiectului).
- **Măsurătorile**  $Y$  (observații cu zgomot) sunt condiționate de starea curentă.






# Urmărirea formelor prin inferență

- **Starea ascunsă**  $X$  este reprezentată de parametrii de interes (poziția obiectului).
- **Măsurătorile**  $Y$  (observații cu zgomot) sunt condiționate de starea curentă.





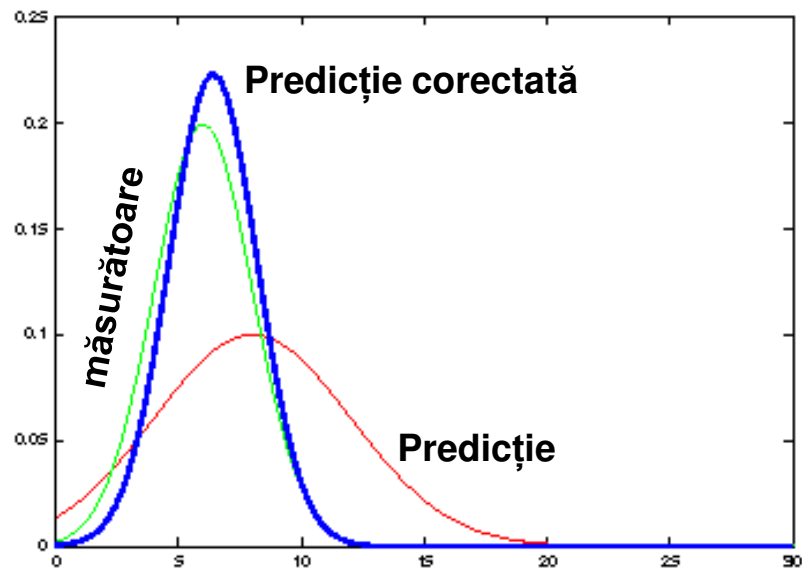

# Urmărirea formelor prin inferență



- La fiecare moment de timp, starea se modifică de la  $X_{t-1}$  la  $X_t$ , efectuând astfel noi observații  $Y_t$
- Obiectiv:
  - Determinarea celei mai probabile stări  $X_t$ , dându-se toate observațiile efectuate.
  - Se cunoaște dinamica tranziției dintre stări.



# Urmărirea formelor prin inferență



**t-1**

**t**



# Presupuneri

- Doar starea precedentă ( $t-1$ ) influențează starea curentă

$$P(\mathbf{X}_i | \mathbf{X}_1, \dots, \mathbf{X}_{i-1}) = P(\mathbf{X}_i | \mathbf{X}_{i-1})$$

- Măsurătorile la momentul de timp  $i$  depind doar de starea curentă

$$P(\mathbf{Y}_i, \mathbf{Y}_j, \dots, \mathbf{Y}_k | \mathbf{X}_i) = P(\mathbf{Y}_i | \mathbf{X}_i) P(\mathbf{Y}_j, \dots, \mathbf{Y}_k | \mathbf{X}_i)$$



# Urmărirea formelor prin inferență

- **Predicție:**

- Dându-se măsurătorile până la momentul de timp  $t-1$ , ce stare se prezice pentru momentul  $t$ ?

$$P(X_t | y_0, \dots, y_{t-1})$$

- **Corecție:**

- Dându-se măsurătoarea curentă ( $t$ ), care este noua stare estimată pentru momentul  $t$ ?

$$P(X_t | y_0, \dots, y_t)$$



# Proces recursiv

- Există un estimat inițial al stării  $P(X_0)$ , ce va fi corectat odată cu prima măsurătoare  $Y_0=y_0$ .
- Dându-se estimatul corectat pentru cadrul  $t-1$ :
  - 1) Predicție estimat pentru cadrul  $t$
  - 2) Corecție estimat pentru cadrul  $t$





## Probleme deschise

- Cum se poate reprezenta dinamica ce guvernează tranziția stărilor?
- Cum se pot descrie relațiile dintre stări și măsurători, luând în considerare și incertitudinea (zgomotul) măsurărilor?
- Cum se poate calcula corecția stării, având noile măsurători și starea precedentă?
  
- Se vor lua în considerare *modele dinamice liniare*, reprezentate de funcții de densitate Gaussiene.
  
- Corecția stării: *Filtrul Kalman*



# Model dinamic liniar

- **Describe informația apriori legată de:**
  - **Modelul dinamic al sistemului: evoluția stării de-a lungul timpului (incluzând zgomotul)**

$$x_t = Dx_{t-1} + \varepsilon$$

- **Modelul dinamic al măsurătorilor: la fiecare moment de timp măsurătoarea obținută conține zgomot**

$$y_t = Mx_t + \xi$$

- **$D, M$ : matrici de tranziție a stărilor**
- **$\varepsilon, \xi$ : zgomot Gaussian adăugat procesului (informație a-priorii)**




# Model dinamic liniar

- $x, y$  - funcții de distribuție Gaussiană
- $\varepsilon, \xi$ : zgomot Gaussian adăugat procesului (informație a-priorii)

$$\varepsilon \sim N(0, Q)$$


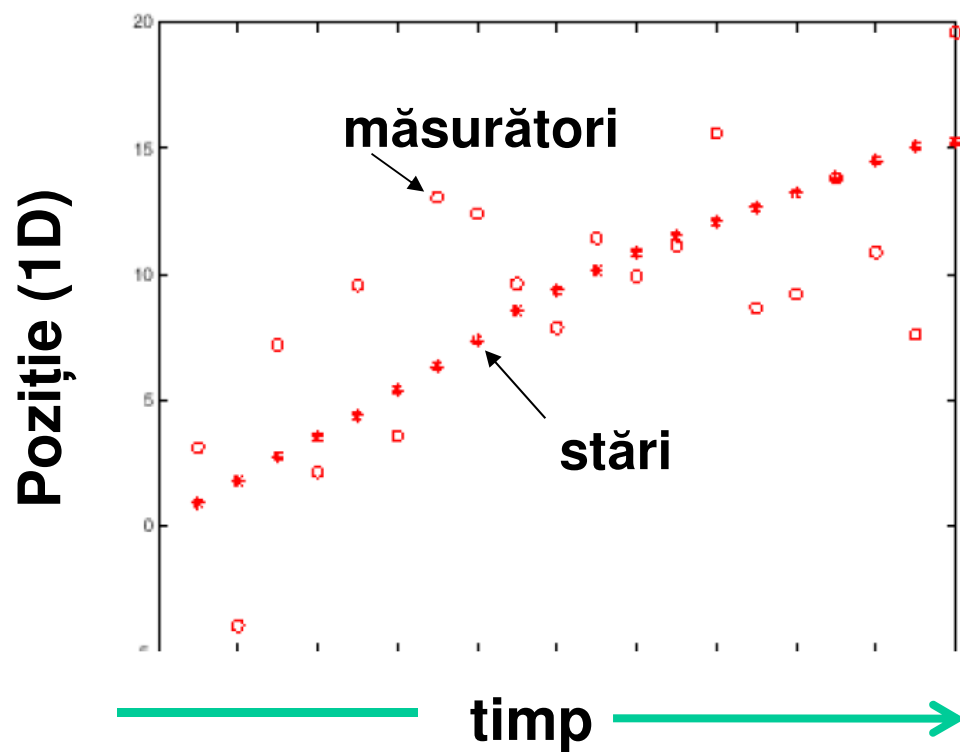
$$\xi \sim N(0, R)$$

- $Q, R$  – matrici de covarianță a zgomotului





# Exemplu: viteză constantă



Poziție (1D)



## Exemplu: viteză constantă

- Starea: poziția  $p$  și viteza  $v$

$$x_t = \begin{bmatrix} p_t \\ v_t \end{bmatrix} \quad p_t = p_{t-1} + (\Delta t)v_{t-1} + \varepsilon$$

$$x_t = D_t x_{t-1} + zgomot = \begin{bmatrix} 1 & \Delta t \\ 0 & 1 \end{bmatrix} \begin{bmatrix} p_{t-1} \\ v_{t-1} \end{bmatrix} + zgomot$$

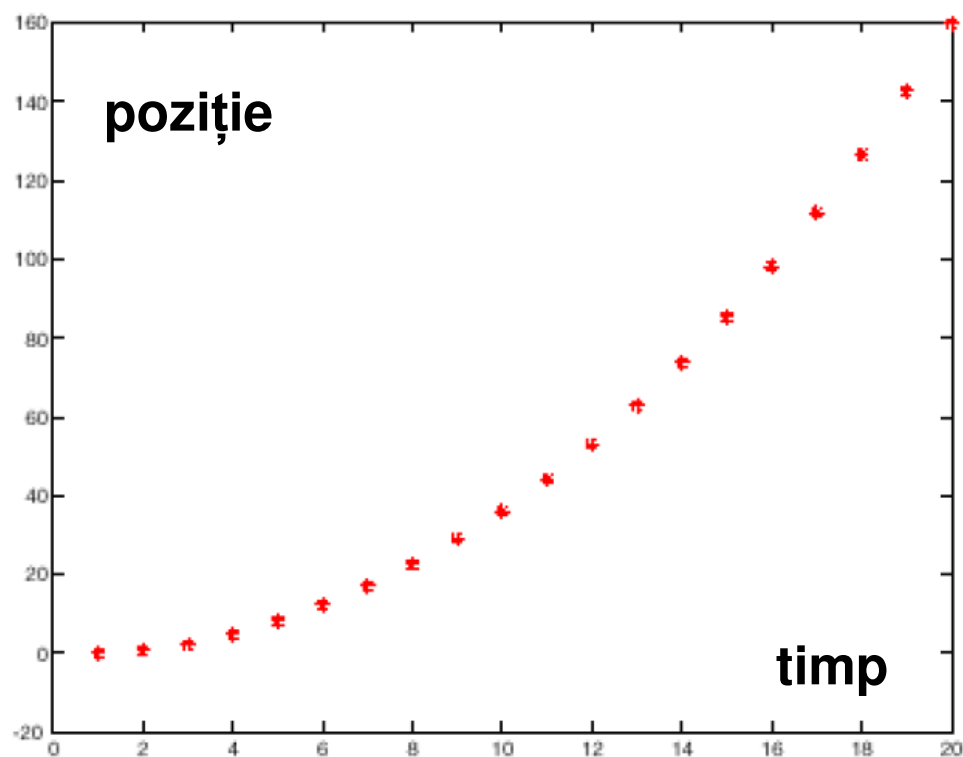
- Măsurătoarea: poziția  $p$

$$y_t = Mx_t + zgomot =$$

$\varepsilon, \xi$  - zgomot



# Exemplu: accelerație constantă





## Exemplu: accelerație constantă

- **Stare: poziție  $p$ , viteză  $v$ , accelerație  $a$ .**

$$x_t = \begin{bmatrix} p_t \\ v_t \\ a_t \end{bmatrix} \quad \begin{array}{l} p_t = p_{t-1} + (\Delta t)v_{t-1} + \varepsilon \\ v_t = \\ a_t = \end{array}$$

$$x_t = D_t x_{t-1} + z_{gomot} =$$

- **Măsurătoare: poziție**

$$y_t = Mx_t + z_{gomot} =$$



# Corecția stării: Filtrul Kalman

$$K_{t+1} = \frac{P_{t+1|t} M^T}{M P_{t+1|t} M^T + R}$$

$$\hat{\mathbf{x}}_{t+1} = \hat{\mathbf{x}}_{t+1|t} + K_{t+1} (\mathbf{y}_{t+1} - M \hat{\mathbf{x}}_{t+1|t})$$

$$P_{t+1} = P_{t+1|t} - K_{t+1} M P_{t+1|t}$$

- $K$  – matrice de amplificare Kalman
- $P$  – matricea de covarianță a erorii (calculată din stările  $x_k$  și  $x_{k+1}$ )
- Pentru obținerea unei stări estimate cât mai precise în raport cu starea sistemului, incertitudinea trebuie să fie cât mai mică.
- ***Filtrul Kalman este un filtru optimal în sensul că acesta minimizează matricea de covarianță a erorii  $P$ .***

