

# Detektory oblastí

Karel Horák



---

Rozvrh přednášky:

1. Úvod.
2. Shi&Tomasi.
3. FAST.

# Detektory oblastí

Karel Horák



---

Rozvrh přednášky:

- 1. Úvod.**
2. Shi&Tomasi.
3. FAST.

# Úvod

- ▶ Detektory významných bodů (rohů - corner features) a oblastí (blob features):
- ▶ Moravcův operátor
- ▶ Harrisův detektor
- ▶ Shi&Tomasi (GFT = Good Features to Track)
- ▶ FAST (Features from Accelerated Segment Test)
- ▶ BRISK (Binary Robust Invariant Scalable Keypoints)
- ▶ FREAK (Fast Retina Keypoint)
- ▶ HOG (Histogram of Oriented Gradients)
- ▶ GLOH (Gradient Location and Orientation Histogram)
- ▶ BRIEF (Binary Robust Independent Elementary Features)
- ▶ ORB (Oriented FAST and Rotated BRIEF)
- ▶ MSER (Maximally Stable Extremal Regions)
- ▶ SIFT (Scale-Invariant Feature Transform)
- ▶ SURF (Speeded-Up Robust Features)

# Úvod

## ► Literatura chronologicky:

- [1] Moravec, H. P. Towards Automatic Visual Obstacle Avoidance. 1977. (**Moravec<sup>2</sup>**)
- [2] Harris, C., Stephens, M. A Combined Corner and Edge Detector. 1988. (**Harris<sup>2</sup>**)
- [3] Shi, J., Tomasi, C. Good Features to Track. 1994. (**Shi-Tomasi<sup>1</sup>**)
- [4] Matas, J., et al. Robust wide baseline stereo from maximally stable extremal regions. 2002. (**MSER<sup>2</sup>**)
- [5] Lowe, D. G. Distinctive Image Features from Scale-Invariant Keypoints. 2004. (**SIFT<sup>2</sup>**)
- [6] Mikolajczyk, K., Schmid, C. A performance evaluation of local descriptors. 2005. (**GLOH<sup>3</sup>**)
- [7] Rosten, E., Drummond, T. Fusing Points and Lines for High Performance Tracking. 2005. (**FAST<sup>1</sup>**)
- [8] Dalal, N., Triggs, B. Histograms of oriented gradients for human detection. 2005. (**HOG<sup>3</sup>**)
- [9] Bay, H., Ess, A., Tuytelaars, T., Gool, L. Van. SURF:Speeded Up Robust Features. 2008. (**SURF<sup>2</sup>**)
- [10] Calonder, M., et al. BRIEF:Binary Robust Independent Elementary Features. 2010. (**BRIEF<sup>3</sup>**)
- [11] Leutenegger, S., Chli, M., Siegwart, R. BRISK: Binary Robust Invariant Scalable Keypoints. 2011. (**BRISK<sup>3</sup>**)
- [12] Rublee, E., et al. ORB: An efficient alternative to SIFT or SURF. 2011. (**ORB<sup>3</sup>**)
- [13] Alahi, A., Ortiz, R., Vandergheynst, P. FREAK: Fast Retina Keypoint. 2012. (**FREAK<sup>3</sup>**)

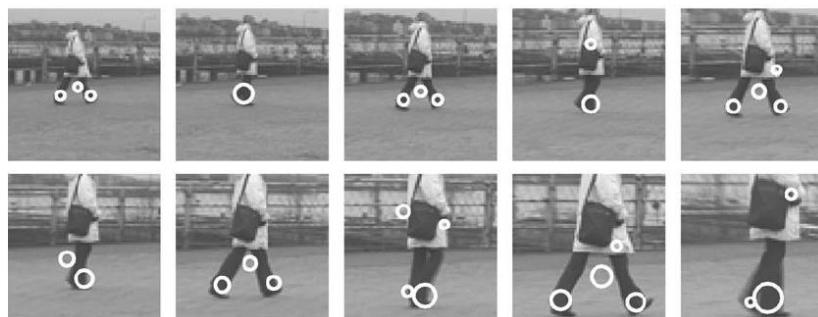
► <sup>1</sup> probráno v tomto materiálu

► <sup>2</sup> probráno v jiném materiálu

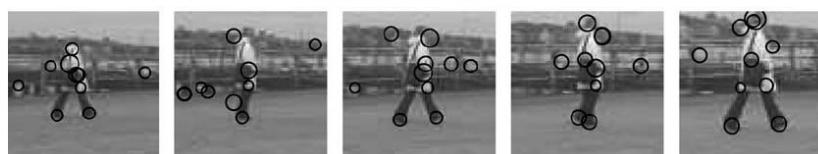
► <sup>3</sup> neprobráno

# Úvod

- Co od významných bodů očekáváme?
- Stabilita – nezávislost detekce na obecné affinní transformaci (translace, rotace, zkosení, měřítko),  
*Spatio-temporal interest points*



*Spatial interest points*



- Opakovatelnost – detekce stejného znaku ve dvou a více různých snímcích stejné scény



# Detektory a deskriptory oblastí

Karel Horák



---

Rozvrh přednášky:

1. Úvod.
- 2. Shi&Tomasi.**
3. FAST.
4. MSER.
5. SIFT.
6. SURF.

# Shi&Tomasi

- ▶ Shi&Tomasi (někdy odkazováno jako Kanade&Tomasi)
- ▶ Nejde o prostý detektor významných bodů na jednom statickém obrazu (popř. dvou po sobě jdoucích obrazech pro nalezení korespondencí), ale o komplexní techniku pro sledování trajektorie významných bodů ve videosekvenci.
- ▶ Nový pojem – kvalita významného bodu: ne každý významný bod ve statickém obrazu je významný v sekvenci obrazů pro sledování.
- ▶ Důvod? Detekovaný významný bod nemusí nutně reprezentovat fyzický bod ve scéně.

Given Sequence

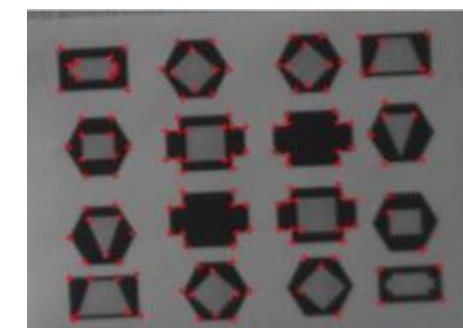
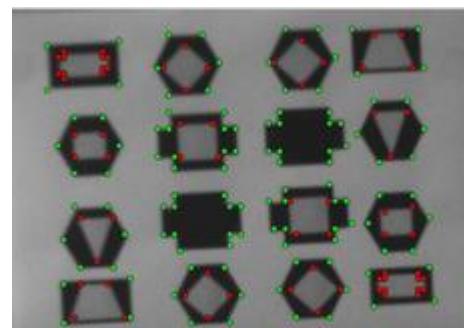


Antenna and mirror support bar create a feature which does not correlate to a real-world feature



# Shi&Tomasi

- ▶ Významné body stabilní nejen ve statickém obrazu, ale i dalších obrazech sekvence jsou pak ad-hoc nazývány Good Features to Track (GFT).
- ▶ Dvě třídy úloh, kde lze GFT použít:
  - 1) sledování pohybujícího se objektu ve scéně - kamera fixní nebo plovoucí (vektory pohybu se sčítají)
  - 2) rekonstrukce 3D prostoru/objektu při pohybující se kameře
- ▶ Metoda Shi&Tomasi může být rozdělena na dvě fáze:
  1. detekce významných bodů ve statickém obrazu (používá podobný formalismus jako Harris)
  2. filtrace GFT
- ▶ Filosofie metody: pro každý sledovaný znak/rys (feature) je v průběhu videosekvence monitorována jeho kvalita pomocí tzv. nepodobnosti = rozdíl vzhledu znaku v aktuálním snímku a vzhledu původního znaku (např. z prvního snímku sekvence) -> pokud nepodobnost překročí práh, je daný znak z dalšího sledování vypuštěn
- ▶ Testovací obrazec s rohy typu L, T, X a Y:
  - ▶ 180 bodů = 112 vnější (zelená)
  - + 70 vnitřní (červená)
  - ▶ Obraz vpravo = odezva Shi-Tomasi



# Shi&Tomasi

- Ad 1. detekce významných bodů:
- Podobná matematika jako u Harrise – symetrická matice 2x2 kvadrátů gradientů:

$$C(x, y) = \begin{bmatrix} \sum_w I_x^2(u, v) & \sum_w I_x(u, v) \cdot I_y(u, v) \\ \sum_w I_x(u, v) \cdot I_y(u, v) & \sum_w I_y^2(u, v) \end{bmatrix}$$

- Podmínky na významný bod:
  - matice musí být nad úrovní šumu (šum je v podstatě nespolehlivý významný bod)
  - matice musí být dobře podmíněná (viz podmíněnost matice)

Ad a) – obě vlastní čísla  $\lambda_1$  a  $\lambda_2$  matice musí být dostatečně velká

Ad b) – obě vlastní čísla matice se navzájem nesmí lišit o několik řádů (pak by to nebyl bidirekcionál jako např. roh nebo pepř&sůl vzor, ale hrana nesoucí informaci o pohybu pouze v jednom směru – unidirekcionál)

- Prakticky navíc platí úvaha – pokud je menší z vlastních čísel nad úrovní šumu (podmínka 1), je matice zpravidla zároveň i dobře podmíněná (podmínka 2), protože kvůli maximální přípustné jasové hodnotě pixelů (např. 255) nemůže být hodnota většího vlastního čísla libovolně vysoká.

# Shi&Tomasi

- Ad 1. detekce významných bodů:
- Z toho tedy vyplývá, že jako GFT uznáme okno kolem bodu, pro nějž platí:

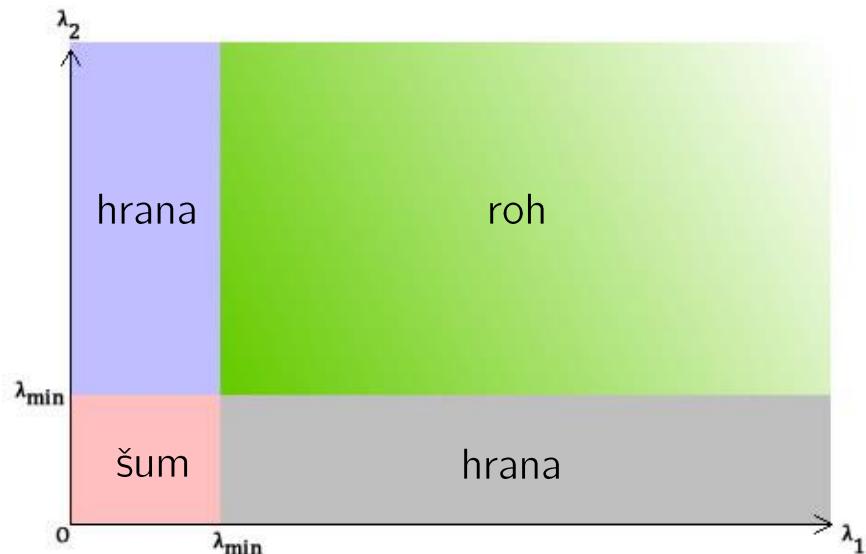
$$\min(\lambda_1, \lambda_2) > \lambda$$

- kde  $\lambda$  je předdefinovaný práh.
- Rozdíl v implementaci Shi&Tomasi vs. Harris:

$$H(\lambda_1, \lambda_2) = \lambda_1 \cdot \lambda_2 - \kappa \cdot (\lambda_1 + \lambda_2)^2 = \det(C) - \kappa \cdot \text{trace}(C)^2$$

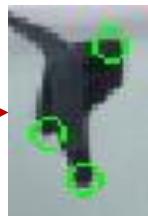


Narozdíl od Shi&Tomasi není nutné vůbec počítat vlastní čísla matice – stačí vyjádřit determinant a stopu.



# Shi&Tomasi

- Detekční rozdíl Shi&Tomasi (vlevo) vs. Harris:



# Shi&Tomasi

- ## ► Ad 2. Filtrace GFT:

- Předpoklad pro změnu scény/obrazu za čas  $\tau$ :

$$I(x, y, t + \tau) = I(x - \xi(x, y, t, \tau), y - \eta(x, y, t, \tau))$$

- Slovy: změnu obrazové funkce uvažujeme pouze jako translaci v ose x a ose y danou funkcí  $\delta$ :

$$\delta = (\xi, \eta)$$

- tj. vůbec nepředpokládáme změnu jasu pixelů – stín, překrytí, odraz/lom světla apod. – to je **extrémně silný předpoklad**, který nás záhy zastaví (\*).

- Posun  $\delta$  je approximován pomocí affinní transformace (rotace, měřítko, zkosení, translace):

$$D = \begin{bmatrix} d_{xx} & d_{xy} \\ d_{yx} & d_{yy} \end{bmatrix}$$

deformační matice  
(affinní transformace)

$$\delta = D\mathbf{x} + \mathbf{d}$$


 $\mathbf{x} = \begin{bmatrix} x \\ y \end{bmatrix}$

polohový vektor

$$\mathbf{d} = \begin{bmatrix} d_x \\ d_y \end{bmatrix}$$

vektor translace  
(střed okna znaku)

- Pozn.: afinita = spřízněnost, podobnost (affinní transformace nemění topologii tj. blízké body jsou transformovány opět na blízké body)

# Shi&Tomasi

- Ad 2. Filtrace GFT:

- Pak lze snadno vyvodit, že změna polohy bodu  $\mathbf{x}$  z obrazu  $I$  bude v obrazu  $J$  dána:

$$J(A\mathbf{x} + \mathbf{d}) = I(\mathbf{x})$$

- kde  $A = \mathbf{1} + D$  ( $\mathbf{1} = 2 \times 2$  jednotková matice)
- Sledování bodu  $\mathbf{x}$  lze pak chápat jako výpočet šesti parametrů (4 v  $D$ , dva v  $\mathbf{d}$ ) v každé iteraci – tento odhad parametrů se děje z hodnot v určitém okolí (okně)  $W$  kolem bodu  $\mathbf{x}$ .
- Problém 1 – velikost okna: u příliš malého okna se špatně/nepřesně počítají parametry affinní transformace, u velkého je zase výpočet dlouhý.
- Problém 2 – ideální model: na reálných datech není rovnice nahoře splnitelná a výpočet šesti parametrů je velmi nepřesný a nestabilní. (\*)
- Proto se úloha odhadu pohybu předefinuje jako minimalizace odchylky (nepodobnosti)  $J$  a  $I$ :

$$K = \iint_W [J(A\mathbf{x} + \mathbf{d}) - I(\mathbf{x})]^2 w(\mathbf{x}) d\mathbf{x}$$

váhovací funkce  
(binární nebo Gauss)

# Shi&Tomasi

- Demonstrace rozdílu použití Haarových příznaků a GFT pro detekci obličeje ve videu:



Haarovy příznaky

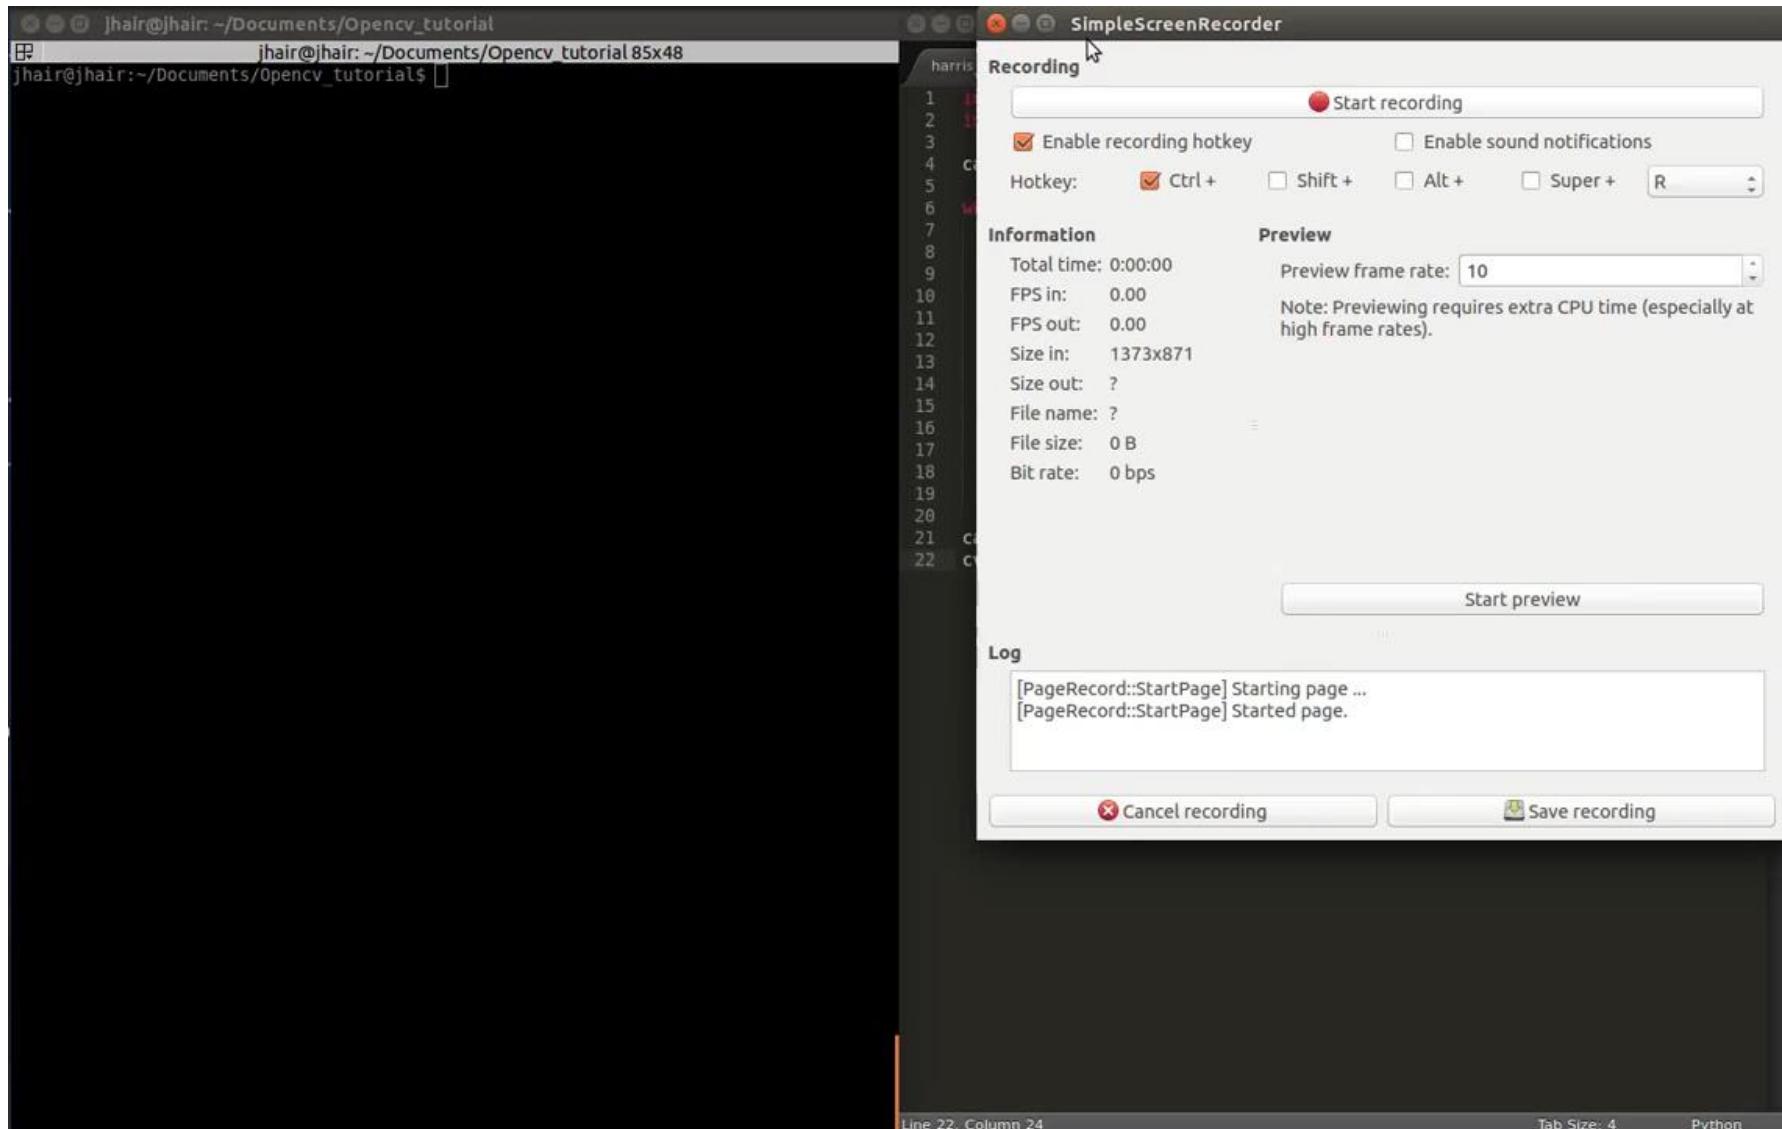
Good Features to Track + optický tok

pozn.: na začátku je potřeba jednou nalézt objekt (obličej)

- Stejným způsobem pracuje sledování libovolného objektu, u nějž známe GFT.

# Shi&Tomasi

- Ukázka: detektor rohu Shi-Tomasi – implementace v OpenCV 3.0 beta:

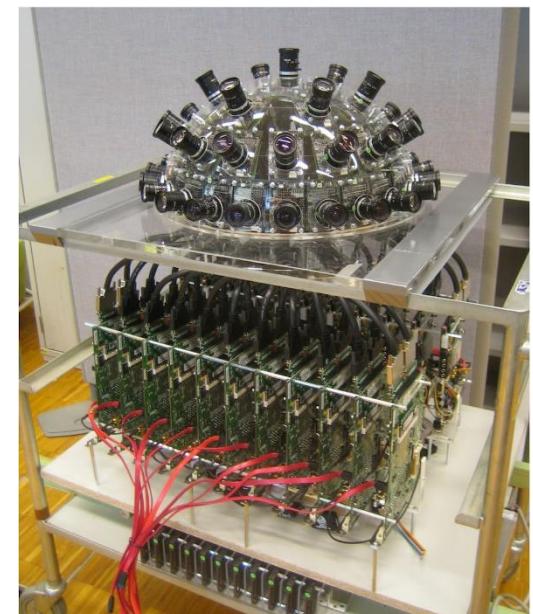


# Shi&Tomasi

- Ukázka: výpočet optického toku v úloze všesměrového (omnidirekcionálního) vidění – významné body pro korespondenci jsou získány pomocí Shi-Tomasi detektoru.



- Pro zajímavost – jak vypadá omnidirekcionální kamera?



Courtesy of: Allied Vision Technologies / Point Grey / EPFL

# Detektory oblastí

Karel Horák



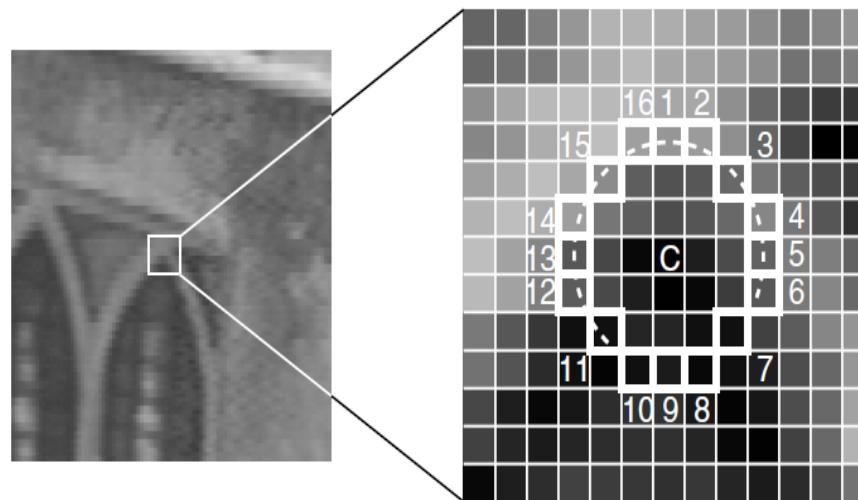
---

Rozvrh přednášky:

1. Úvod.
2. Shi&Tomasi.
- 3. FAST.**

# FAST

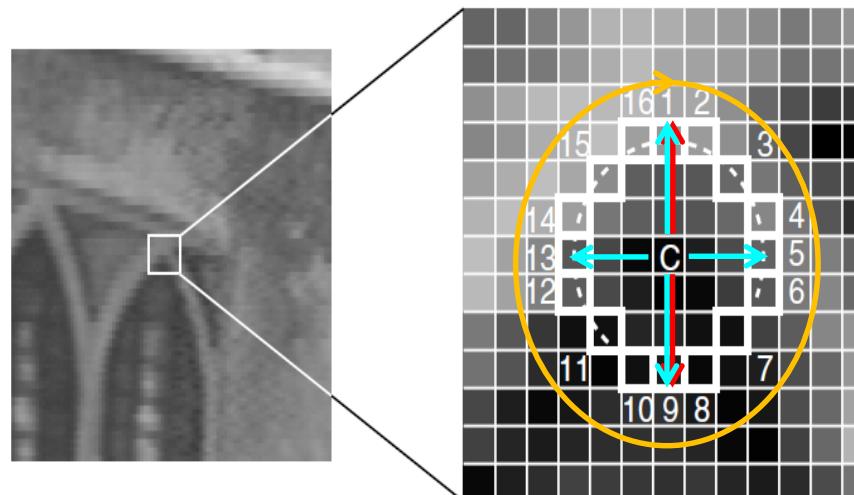
- FAST = Feature from Accelerated Segment Test
- Patří do třídy algoritmů AST (Accelerated Segment Test), které jsou orientovány na nízkou výpočetní náročnost.
- Princip: pro určení, zda bod C je významným bodem je zkoumána rozdílnost jasových hodnot 16 pixelů ležících na kružnici o poloměru 3 kolem bodu C.



- Pokud jsou jasové hodnoty určitého počtu pixelů  $n \in \{1, 16\}$  současně všechny větší nebo současně všechny menší o předem daný práh  $t$ , je bod C prohlášen za významný.
- Obvykle se jako hodnota oddělující výraznou hranu od rohu uvádí  $n = 12$  (hledáme tedy  $n \geq 12$ ).

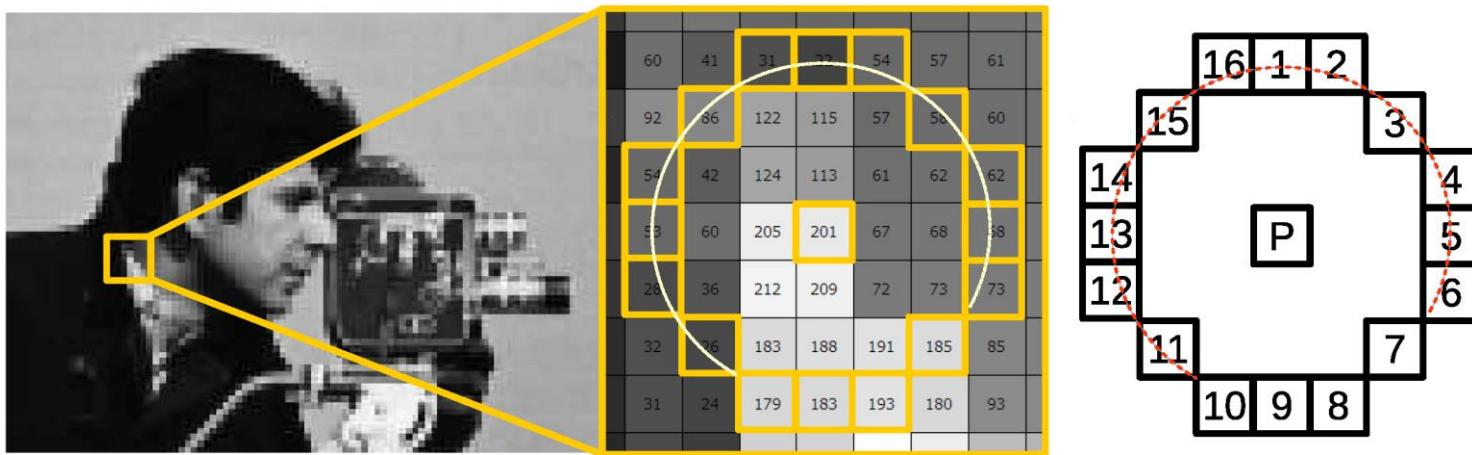
# FAST

- Algoritmus musí být rychlý tj. záleží na pořadí testování rozdílů jasových hodnot pixelů  $P_1$  až  $P_{16}$  a postup je samozřejmě deterministický.
- Pomocí experimentu s rozhodovacím stromem ID3 byla nalezena výpočetně optimální sekvence testování pixelů (nejkratší strom).
- Kroky algoritmu (k následujícímu kroku se přechází pouze při splnění předchozího - bod C tedy může být významným bodem pouze tehdy, projdeme-li úspěšně všechny body algoritmu):
  1. jasová hodnota alespoň jednoho pixelu z  $(P_1, P_9)$  leží mimo interval  $\langle I_C-t, I_C+t \rangle$
  2. jasové hodnoty alespoň tří pixelů z  $(P_1, P_5, P_9, P_{13})$  leží mimo interval  $\langle I_C-t, I_C+t \rangle$
  3. porovnání ostatních hodnot  $\langle P_1:P_{16} \rangle$  s C a testování podmínky  $n \geq 12$



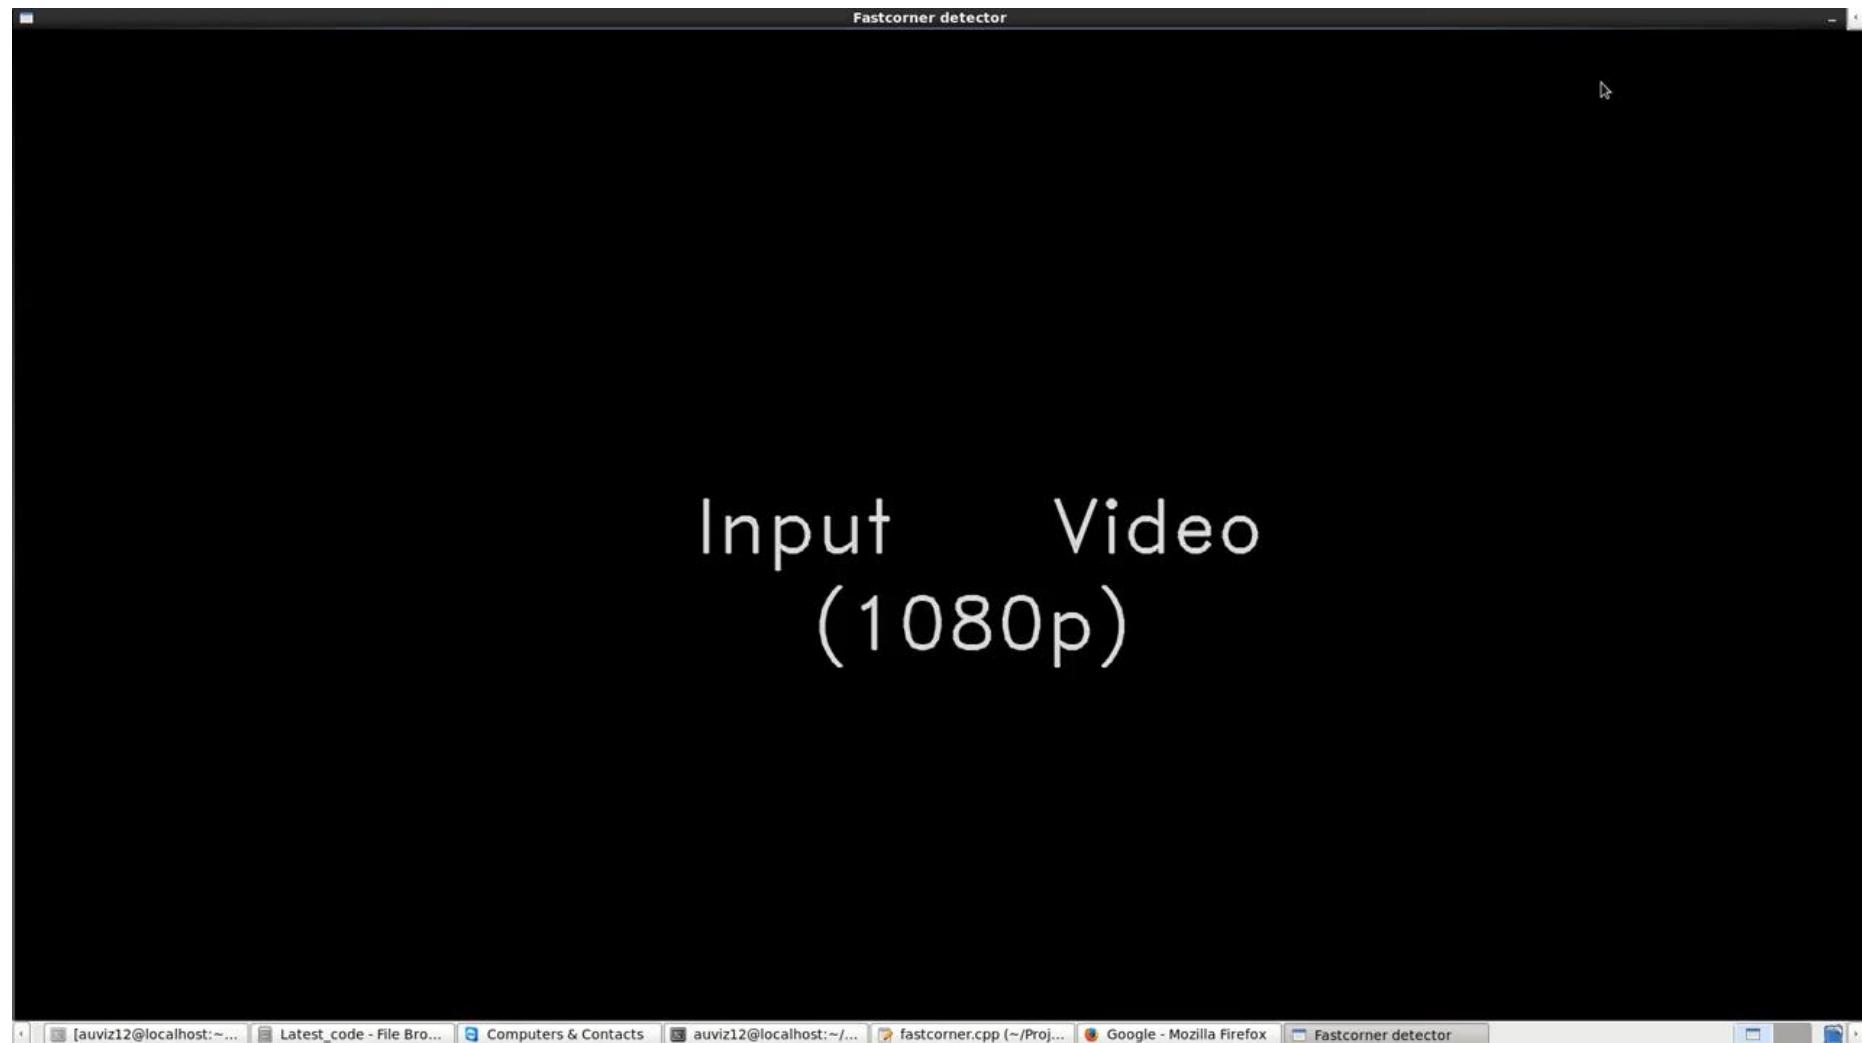
# FAST

- K algoritmu:



# FAST

- Ukázka – detekce významných bodů v dopravě:

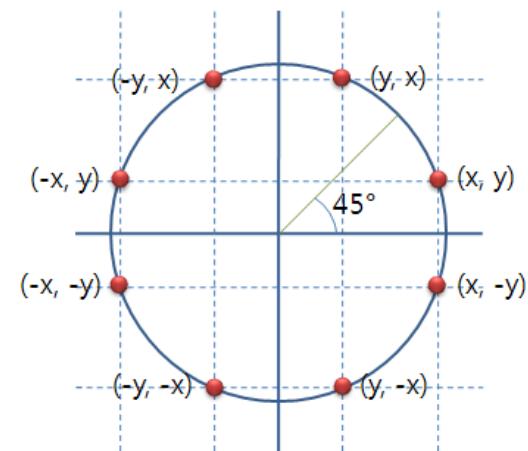
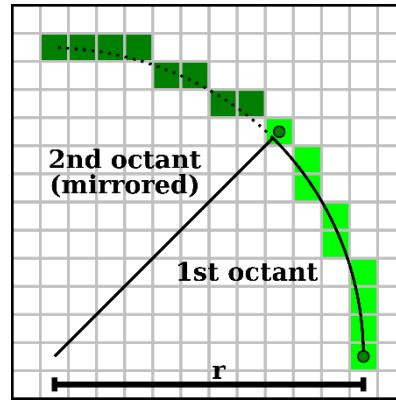


# FAST

- ▶ Poznámky k rychlosti FAST:
- ▶ Poloměr  $r=3$  je specificky používaný u algoritmu FAST a je pro něj stanoveno optimální pořadí testování pixelů (viz předchozí slide), nicméně teoreticky i prakticky lze implementovat i jiné  $r$ .
- ▶ Pro výpočet souřadnic  $(x,y)$  bodů ležících na kružnici se zpravidla používá Bresenhamův algoritmus:
  1. ve spodní polovině prvního kvadrantu (první oktant) spočítej pro všechna přípustná  $x$  odpovídající  $y$
  2. zrcadlením hodnot (záměnou souřadnic  $x$  a  $y$ ) do druhého oktantu kompletuj první kvadrant
  3. postupnou záměnou znamének souřadnic  $x$  a  $y$  kompletuj 2., 3. a 4. kvadrant

$$f_{circle}(x, y) = (x - x_c)^2 + (y - y_c)^2 - r^2$$

$$f_{circle}(x, y) = \begin{cases} < 0 & \text{inside the circle boundary} \\ = 0 & \text{on the circle boundary} \\ > 0 & \text{outside the circle boundary} \end{cases}$$



- ▶ FAST-ER modifikace: FAST + Enhanced Repeatability, větší opakovatelnost

# FAST

- ▶ Srovnání výpočetní náročnosti různých detektorů významných bodů (video 640x480 / 30 FPS)

Detector	Training set		Test set	
	Pixel rate (MPix/s)	%	MPix/s	%
FAST $n = 9$	188	4.90	179	5.15
FAST $n = 12$	158	5.88	154	5.98
Original FAST ( $n = 12$ )	79.0	11.7	82.2	11.2
FAST-ER	75.4	12.2	67.5	13.7
SUSAN	12.3	74.7	13.6	67.9
Harris	8.05	115	7.90	117
Shi-Tomasi	6.50	142	6.50	142
DoG	4.72	195	5.10	179