

Robotické vysavače

pro výuku mobilní robotiky

Pavel Krsek

2. 6. 2021

- ◆ Robot Turtlebot a senzory
- ◆ Studentské úlohy a kroky k řešení
- ◆ Obraz z kamery a postup zpracování
- ◆ Hranová detekce, Houghova transformace
- ◆ Barevný prostor, segmentace a popis oblastí



České vysoké učení technické v Praze (ČVUT, CTU)

Český institut informatiky, robotiky a kybernetiky (CIIRC)

Výuka

- ◆ **Fakulta elektrotechnická,**
Katedra kybernetiky
- ◆ Laboratoře robotiky
(bakalář, 4. semestr)

Další navazující předměty

- ◆ Inteligentní robotika
(magistr, 2. semestr)
- ◆ Mobilní a kolektivní robotika
(magistr, 3. semestr)



Robot TurtleBot

Pohon

- ◆ Dvě samostatně hnaná kola
(nastavuje se rychlost jízdy a otáčení)

Senzory

- ◆ Intel RealSens (Microsoft Kinect)
 - RGB kamera (640x480)
 - 3D hloubková kamera (640x480)
- ◆ Nárazník v přední části
- ◆ Tlačítka, display ...

Řídicí počítač

- ◆ Intel NUC i5
- ◆ Paměť 8GB RAM, 128GB SSD





System

- ◆ Operační systém Linux (Ubuntu 18)
- ◆ ROS, verze Melodic
Robot Operating System
- ◆ Interface pro Python (objekt)
- ◆ Gazebo - simulátor

Programování

- ◆ Python 2.7 (omezeno ROS)
- ◆ Knihovna OpenCV
Algoritmy pro zpracování obrazu
- ◆ Numpy pro výpočty



Kamera a hlubokový senzor (depth camera)




5/37

Parametry hlubkových snímačů



Orbbec Astra



RealSense R200



RealSense D415

FOV [stupňů]:	60 x 49.5	59 x 45.5	65 x 40
Rozsah [m]:	0.6 ... 8.0	0.5 ... 3.5 (4.0)	0.45 ... 3.0
Chyba XY [mm]:	7.2 (3m)	—	—
Chyba Z [mm]:	12.7 (3m)	10 (2m)	2% (2m)
Rozlišení [px]:	640x480	640x480	1280x720

Stránky výrobců

- ◆ <https://www.intel.com/content/www/us/en/architecture-and-technology>
- ◆ <https://orbbec3d.com>


Orázky: stránky výrobců

Snímky poskytované senzorem



6/37

- ◆ Rozlišení 640x480 bodů
- ◆ RealSense D415 má menší minimální hloubku (31 cm), rychlejší
- ◆ Snímky jsou geometricky přibližně zarovnané







Řešené úlohy

Parkování (příčné, ke zdi)





Jízda v pruhu



Slalom mezi sloupky



Hledání (srážení) sloupku





Obraz z kamery


Pořízení obrazu a jeho reprezentace

Světlo = elektromagnetické záření

Viditelná část spektra: 390–760 nm (390–790 THz)

Parametry záření:

- ◆ Frekvence záření (vlnová délka) je detekována kamerou nepřímo.
- ◆ Amplituda (intenzita) je snímána kamerou přímo.
- ◆ Polarizace (příčné vlny) se snímá pomocí polarizačních filtrů.
- ◆ Fáze má význam pouze pro koherentních zobrazení (holografie, interferometrie).



vlnová délka uvedena v nanometrech [nm]


Formování obrazu

Klasický objektiv

- ◆ Vzdálenost objektu \gg ohnisková vzdálenost.
- ◆ Objektiv modelujeme jako tenkou čočku (středové promítání)




Vznik obrazu

- ◆ Světlo se odráží od povrchu objektu.
- ◆ Odražené světlo promítá objektiv na čip (snímač).
- ◆ Snímač převádí světlo (fotony) na elektrický signál.



Obvyklá realizace snímače

- ◆ Snímač se skládá z jednotlivých citlivých buněk - obrazových bodů.
- ◆ Dopadající světlo (fotony) se v polovodiči mění na nábojové páry (elektron-díra).
- ◆ Nábojové páry se ve statickém elektrickém poli mění na proudové impulzy.
- ◆ Impulzy jsou po dobu expozice integrovány nabíjením/vybíjením kondenzátoru.
- ◆ Obrazové body tvoří pravoúhlou síť se stejnými rozestupy v obou směrech.





Vliv osvětlení na obraz

Rubikova kostka

- ◆ Osvětlená sluncem.
- ◆ Stín zprava osvětlen navíc žárovkou.
- ◆ Různé nastavení vyvážení bílé.



Barevné spektrum

- ◆ Osvětlené sluncem.
- ◆ Stín vlevo osvětlen navíc žárovkou.



RGB snímek




14/37



```
value = image[řádek, sloupec, barva]
value ∈ ⟨0; 255⟩
barva ∈ [0, 1, 2] ≡ B, G, R
```

```
im_rgb = cv2.cvtColor(im_bgr, cv2.COLOR_BGR2RGB)
```



Detekce přímek

- ◆ Detekce hran
- ◆ Houghova transformace



Segmentace a výběr oblastí

- ◆ Barevný prostor a prahování
- ◆ Spojité oblasti (labeling)
- ◆ Popis oblastí



Detekce hran

Významná změna jasu ve snímku

Převod z barevného na černobílý obraz



17/37

Způsoby převodu

1. $I = 0.333I_R + 0.333I_G + 0.333I_B$

2. $I = 0.299I_R + 0.587I_G + 0.114I_B$

Realizace

```
gray = cv2.cvtColor(im, cv2.COLOR_BGR2GRAY)
```



1



2



Detekce hran ve snímku (edge detection)

Jednoduše: Hrana je místo ve snímku, kde se výrazně mění jeho jas (intenzita).

Sobelův hranový detektor

- ◆ Konvoluce obrazu s maskou pro svislé a vodorovné hrany:

$$K_x = \begin{bmatrix} +1 & 0 & -1 \\ +2 & 0 & -2 \\ +1 & 0 & -1 \end{bmatrix}, K_y = \begin{bmatrix} +1 & +2 & +1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}.$$



- ◆ Intenzita hrany v daném bodě je $G = \sqrt{G_x^2 + G_y^2}$.
- ◆ Nastavuje se práh intenzity G .

Realizace

```
Gx = cv2.Sobel(img, cv2.CV_64F, 1, 0, ksize=3)
Gy = cv2.Sobel(img, cv2.CV_64F, 0, 1, ksize=3)
G = np.sqrt(Gx**2 + Gy**2)
```



Vstupní snímek



Sobelův detektor



Detekce hran na základě 2. derivace

Jinak: Extrém detekujeme jako pomocí derivace.

Proto: Používáme 2. derivaci jasové funkce

Metoda Laplacián/Gaussián

- ◆ Detekce používá Laplaceův operátor kombinovaný s Gausovským filtrem.
- ◆ Konvoluční jádro:

$$K_L = \begin{bmatrix} 0 & 1 & 0 \\ 1 & -4 & 1 \\ 0 & 1 & 0 \end{bmatrix}.$$


- ◆ Detekují se průchody nulou 2. derivace obrazové funkce
- ◆ Nastavuje se práh na detekci hrany a σ filtru.

Realizace

```
laplacian =  
cv2.Laplacian(img, cv2.CV_64F, ksize = 1)
```



Vstupní snímek



Laplacián/Gaussián

Cannyho hranový detektor (1986)



20/37

Popis algoritmu


1. Omezení vlivu šumu Gaussovým filtrem.
2. Hrany jsou detekovány Sobelovým operátorem.
3. Intenzita a směr $G = \sqrt{G_x^2 + G_y^2}$, $\Theta = \text{atan2}(G_y, G_x)$.
4. Provedeno “ztenčení” hran ve směru kolmém na hranu (4 směry). Ponechá pouze body s maximální intenzitou.
5. Dvojitě prahování a sledování hrany:
 - ◆ Jsou vybrány body, které mají intenzitu větší než horní práh T_1 (silné hrany).
 - ◆ Postupně jsou jako hranové body označovány body sousedící s hranovými, pokud je intenzita hrany v daném bodě větší než dolní práh T_2 .

Realizace


```
edges = cv2.Canny(img, T1, T2, apertureSize = 3)
```



$\sigma = \sqrt{2}$, $T_1 = 0.01$



$\sigma = \sqrt{2}$, $T_1 = 0.1$



$\sigma = \sqrt{2}$, $T_1 = 0.3$



Houghovy transformace

Detekce přímek v obraze (detekované hrany)



Principy Houghovy transformace

- ◆ Hledáme instance křivky definované rovnicí $f(\mathbf{u}, \mathbf{a}) = 0$, kde \mathbf{u} jsou souřadnice ve snímku a \mathbf{a} je parametrizace hledané křivky.
- ◆ Vstupem jsou obvykle body na hranách (edge detection).
- ◆ Každý hraniční bod může ležet na nekonečně mnoho instancích hledaných křivek.
- ◆ Transformujeme body ze souřadnic snímku do souřadnic parametrů \mathbf{a} křivky.

Algoritmus Houghovy transformace


1. Provedeme kvantizaci vektoru parametrů \mathbf{a} .
2. Vytvoříme n -rozměrné pole akumulátoru $\mathbf{A}(\mathbf{a})$, které strukturou odpovídá parametrům \mathbf{a} .
3. Pro každý nalezený hraniční bod $\mathbf{u} = [u, v]$ v obraze budeme inkrementovat všechny prvky akumulátoru $\mathbf{A}(\mathbf{a})$ pro něž platí $f(\mathbf{u}, \mathbf{a}) = 0$.
4. Po započtení všech hraničních bodů platí, že lokální maxima v akumulátoru $\mathbf{A}(\mathbf{a})$ odpovídají jednotlivým instancím křivky $f(\mathbf{u}, \mathbf{a}) = 0$

Parametrizace přímky



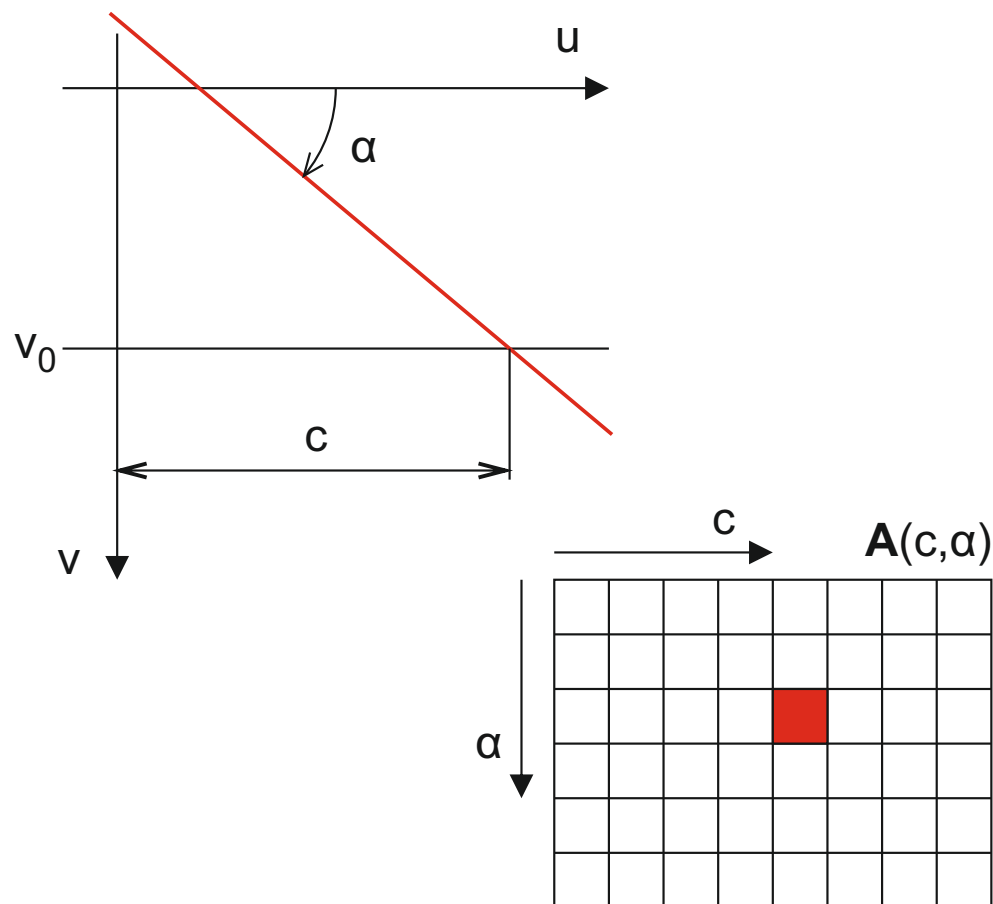
23/37

Obvyklá parametrizace



$$u \cos \alpha + v \sin \alpha = c$$

Alternativní parametrizace




$$u - \cot \alpha (v_0 - v) = c$$

Implementace pro přímky




24/37

- ◆ Vstupem je seznam bodů na hranách
- ◆ Hledáme jízdní parkovací pruh. Proto se omezíme na body s řádkovou souřadnicí > 270 .
- ◆ Rozsah parametrů volíme $\alpha \in \langle 20^\circ; 160^\circ \rangle$ a $c \in \langle 0; 640 \rangle$ obrazových bodů.
- ◆ Kvantizace je 1° a 1 obrazový bod.
- ◆ Řádek pro měření polohy $v_0 = 350$



Vstupující hranové body




Výsledek transformace

Houghova transformace pro přímky




25/37

Body v obraze



Pozice v akumulátoru



1. Provedeme kvantizaci parametrů α , c .
2. Vytvoříme n -rozměrné pole akumulátoru $\mathbf{A}(\alpha, c)$.
3. Pro každý bod hrany $\mathbf{u} = [u, v]$ inkrementuje pozice v akumulátoru $\mathbf{A}(\alpha, c)$, které určíme ze vztahu: $u - \cot \alpha (v_0 - v) = c$
4. Po započtení všech hraničních bodů platí, že lokální maxima v akumulátoru $\mathbf{A}(\alpha, c)$ odpovídají jednotlivým přímkám


Detekce přímek v transformovaném obrázku

Lokalizace hran


- ◆ Hledáme maxima v transformovaném obrázku.
- ◆ Maximu splňuje požadavek na minimální podporu > 30 hranových bodů.
- ◆ Na základě parametrů α a c nalezených maxim konstruujeme přímky.

Realizace

```
cv2.HoughLines(image, rho, theta, threshold)
```



Detekovaná maxima




Odpovídající přímky




Interpretace výsledků

- ◆ Jízdní pruh, parkovací místo tvoří rovnoběžky
- ◆ Průsečík rovnoběžek v obraze - úběžník (vanishing point)
- ◆ Jak ovlivní promítané rovnoběžky poloha robotu?




Příčný posun



$$s = 0.4 \text{ m}, h = 0.25 \text{ m}, \alpha = 0^\circ$$
$$e \in \{-0.1, -0.05, 0.0, 0.05, 0.1\} \text{ m}$$

Otáčení (svislá osa)



$$s = 0.4 \text{ m}, h = 0.25 \text{ m}, e = 0 \text{ m}$$
$$\alpha \in \{-20^\circ, -10^\circ, 0^\circ, 10^\circ, 20^\circ\}$$



Segmentace a popis oblastí

Prahování v prostoru HSV, spojitě oblasti,
popis oblastí

Princip segmentace

- ◆ Podstatou je rozdělit obraz na popředí (objekty zájmu) a pozadí.
- ◆ Výstupem segmentace je binární obrázek.
- ◆ Obrazové body popředí/pozadí jsou obvykle reprezentovány log. 1/0.
- ◆ Existuje řada různých metod segmentace




Příklady segmentačních metod:


- ◆ Prahování (thresholding)
- ◆ Shluková analýza (K-means)
- ◆ Hranová detekce (edge detection)
- ◆ Narůstání oblastí na základě podobnosti bodů
- ◆ Aktivní kontury (active contours)
- ◆ Statistické metody (Markov random fields,...)



RGB



HSV



- ◆ Red - intenzita červeného kanálu.
- ◆ Green - intenzita zeleného kanálu.
- ◆ Blue - intenzita modrého kanálu.

- ◆ Hue - odstín barvy odpovídá dominantní vlnové délce (spektrální barvě).
- ◆ Saturation - sytost barvy popisuje, jak je barva vzdálena od neutrální šedé/bílé.
- ◆ Value - hodnota jasu vyjadřuje kolik světla barva odráží.




Snímek v prostoru HSV

element = I^{HSV} [řádek, sloupec, barva], barva $\in [0, 1, 2] \equiv H, S, V$

```
hsv = cv2.cvtColor(im, cv2.COLOR_BGR2HSV)
```



	BGR	HSV
Modrá:	[255, 0, 0]	[120, 255, 255]
Zelená:	[0, 255, 0]	[60, 255, 255]
Červená:	[0, 0, 255]	[0, 255, 255]
Bílá:	[255, 255, 255]	[0, 0, 255]



$H \in \langle 0; 179 \rangle$



$S \in \langle 0; 255 \rangle$



$V \in \langle 0; 255 \rangle$



Prahování (thresholding)

◆ Zvolíme referenční barvu (zelená)

$$I_{ref}^{BGR} = [45, 130, 55] \rightarrow I_{ref}^{HSV} = [56, 167, 130]$$

◆ Definujeme podmínky

1. Odstín barvy je podobný referenční:

$$|I_{ref}^H - I^H| < t_1$$

2. Tmavé oblasti (nejistá barva) nejsou popředím:

$$I^V > t_2$$

3. Hledané objekty jsou barevně saturované:

$$I^S > t_3$$


◆ Stanovíme jednotlivé prahy

- Prahy nastavujeme na základě výsledku segmentace
- Vždy nutno testovat na větším počtu obrázků (různé podmínky)


◆ Realizace

```
ret,mask = cv2.threshold(img,threshold,255,cv2.THRESH_BINARY)
```

```
binary_mask = img > threshold
```



Mírný práh



Optimální práh



Přísný práh



Označení spojitých oblastí (labeling)

- ◆ Vstupem je binární obraz (pozadí/popředí)
- ◆ Výstupem je obraz s indexy (labels) spojitých oblastí
- ◆ Obrazové body každé spojitě oblasti jsou označena vlastním indexem
- ◆ Spojitost oblasti: 4-okolí, 8-okolí

Realizace v OpenCV



```
out = cv2.connectedComponentsWithStats( binary_mask.astype(np.uint8) )
```

out[0] ... počet oblastí, out[1] ... obraz s index oblastí

out[2] ... parametry oblastí [bod nejvíce vlevo, bod nejvýše, šířka, výška, plochy],

out[3] ... střed / těžiště oblasti.

POZOR: První oblast je pozadí (index 0)





OpenCV počítá většinu parametrů na základě obrysu (countour).

```
contours, hierarchy =  
    cv2.findContours(interest, cv2.RETR_EXTERNAL, cv2.CHAIN_APPROX_NONE)  
cnt = contours[k]
```

Parametry spojitých oblastí (Area & Contour Properties)

◆ Plocha S a obvod O

$$\text{Kompaktnost (compactness)} = \frac{O^2}{S}$$

```
area = cv2.contourArea(cnt)  
lng = cv2.arcLength(cnt, True)
```

◆ Střed oblasti (těžiště)

```
M = cv2.moments(cnt)  
cx = (M['m10']/M['m00'])  
cy = (M['m01']/M['m00'])
```

◆ Momenty spojitě oblasti

$$m_{pq} = \sum_u \sum_v u^p v^q I_b(u, v)$$
$$\mu_{pq} = \sum_u \sum_v (u - \bar{u})^p (v - \bar{v})^q I_b(u, v)$$

```
x, y, w, h = cv2.boundingRect(cnt)
```

◆ Nejmenší opsaný obdélník (strany a , b)

$$\text{Pravoúhlost (rectangularity)} = \frac{a \cdot b}{S}$$

```
rect = cv2.minAreaRect(cnt)  
box = cv2.boxPoints(rect)
```

◆ Konvexní obal (plocha H , obvod)

$$\text{Členitost (solidity)} = \frac{S}{H}$$

```
hull = cv2.convexHull(cnt)
```




Výběr oblastí zájmu



35/37


Parametry nalezených oblastí

Objekt	1	2	3	čtverec	kruh
Těžiště [px]	266.8, 347.6	490.9, 304.9	526.6, 281.4		
Šířka, výška [px]	42, 264	34, 168	10, 17		
Plocha [px]	9528.0	3934.5	33.5		
Výška / šířka [-]	6.29	4.94	1.70	1.0	1.0
Kompaktnost $\frac{O^2}{S}$ [-]	52.43	64.58	205.70	16.0	12.57
Pravoúhlost $\frac{a \cdot b}{S}$	1.09	1.40	4.29	1.0	1.27
Členitost $\frac{S}{H}$	0.92	0.83	0.29	1.0	1.0




Nalezení sloupků

- ◆ Hledané objekty jsou relativně velké.
- ◆ Stanovíme podmínku na plochu:
 $S > t_4$ (500).
- ◆ Sloupky jsou v obraze svislé a tenké.
- ◆ Stanovíme podmínku na poměr šířky a výšky: $\frac{h}{w} > t_5$ (4).



Využití výsledků

- ◆ Kamera míří ze středu robotu vpřed.
- ◆ Co vidím ve středu obrazu, tam mířím.
- ◆ Vzdálenost sloupku
 - Rozměry lineárně závisí na vzdálenosti.
 - Experimentem je možné vztah najít.





Zpracování obrazu

[Sonka1993] Mialn Sonka, Vaclav Hlavac a Roger Boyle. *Image Processing, Analysis and Machine Vision*. ISBN: 978-0-412-45570-4, Springer US, 1993.

[Zanuttigh2016] Pietro Zanuttigh, Giulio Marin, Carlo Dal Mutto, Fabio Dominio, Ludovico Minto a Guido Maria Cortelazzo. *Time-of-Flight and Structured Light Depth Cameras: Technology and Applications*. ISBN: 978-3-319-30971-2, Springer, 2016.

Houghova transformace

[DudaHart1972] R.O. Duda a P.E. Hart. *Use of the Hough transformation to detect lines and curves in pictures*. Communications of the ACM, 15(1):11–15, 1972.

[Ballard1981] D.H. Ballard. *Generalizing the Hough transform to detect arbitrary shapes*. Pattern Recognition, ISSN: 0031-3203, 13(2):111 - 122, 1981