

Kapitola 25

Analýza a zpracování obrazu, počítačové vidění a robotika

25.1 Rozsah látky

Seznam oficiálních státnicových otázek:

Matematický model obrazu, 2D Fourierova transformace a konvoluce, vzorkování a kvantování obrazu, změna kontrastu a jasu, odstranění šumu, detekce hran, inverzní a Wienerův filtr, určení vzájemné polohy snímků, problém korespondence bodu a objektu, odstranění geometrických zkreslení snímků, detekce hranic objektů, detekce oblastí, příznaky pro popis a rozpoznávání 2D objektů, momentové invarianty, wavelety a jejich použití, statistická teorie rozpoznávání, klasifikace s učením (Bayessův, lineární a k-NN klasifikátor), klasifikace bez učení (hierarchické a iterační shlukování), počítačové vidění, úvod do počítačové robotiky, plánování cesty mobilního robota.

25.2 Matematický model obrazu

Obrazová funkcia (spojitá), 2D:

$$f : U \subset \mathbb{R}^2 \rightarrow \mathbb{R}^n$$

$$f : [x, y] \rightarrow [a_1, a_2, \dots, a_n]$$

(poloha bodu v rovine -> atributy obrazu (farba, priehľadnosť, ... — \mathbb{R}^4 pre 3529))

Digiálny rastrový obraz:

$$I : \langle 0..m-1 \rangle \times \langle 0..n-1 \rangle \rightarrow \mathbb{R}^n$$

Digitalizácia pomocou filtru \underline{d} :

$$I_f(i, j) = \iint_{\mathbb{R}^2} f(x, y) d(x-i, y-j) dx dy$$

\underline{d} vyjadruje snímáciu charakteristiku digitalizačného zariadenia (fotočidlo, CCD prvok, ...)

25.3 2D Fourierova transformace a konvoluce

Spojitě verze

- Dopředná Fourierova transformace: $F(u, v) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(x, y) e^{-2\pi i(ux+vy)} dx dy$
- Zpětná Fourierova transformace: $f(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} F(u, v) e^{2\pi i(ux+vy)} du dv$
- Konvoluce: $(f * g)(x, y) = (g * f)(x, y) = \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} f(a, b) g(x-a, y-b) da db$

Vlastnosti

- Convolution theorem: $\mathcal{F}\{f * g\} = \mathcal{F}\{f\} \cdot \mathcal{F}\{g\}$
- Linearita: $\mathcal{F}\{a \cdot f + b \cdot g\} = a \cdot \mathcal{F}\{f\} + b \cdot \mathcal{F}\{g\}$
- Shift theorem: $\mathcal{F}\{f(x-x_0, y-y_0)\}(u, v) = e^{-2\pi i(ux_0+vy_0)} F(u, v)$
- Rotace: $\mathcal{F}\{Rot(f)\} = Rot(\mathcal{F}\{f\})$

Diskrétní verze

- Dopředná Fourierova transformace: $F_{n,m} = \frac{1}{\sqrt{MN}} \sum_{k=0}^{N-1} \sum_{l=0}^{M-1} f_{k,l} e^{-2\pi i(\frac{km}{M} + \frac{ln}{N})}$
- Zpětná Fourierova transformace: $f_{k,l} = \frac{1}{\sqrt{MN}} \sum_{m=0}^{N-1} \sum_{n=0}^{M-1} F_{n,m} e^{2\pi i(\frac{km}{M} + \frac{ln}{N})}$
- Konvoluce: $(f * g)[m, n] = \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} f(i, j)g(m - i, n - j)$

25.4 Vzorkování a kvantování obrazu

Matematický model vzorkování, Shannon theorem

$f(x, y) \cdot s(x, y) = d(x, y)$, kde f je původní funkce, s je vzorkovací fce (pole delta funkcí) a d je navzorkovaný obraz.

- $F(u, v) * S(u, v) = D(u, v)$
- $s(x, y) = \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} \delta(x - i\Delta x, y - j\Delta y)$
- $S(u, v) = \sum_{i=-\infty}^{\infty} \sum_{j=-\infty}^{\infty} \delta(u - i\frac{1}{\Delta x}, v - j\frac{1}{\Delta y})$

Fourierův obraz navzorkované funkce ($D(u, v)$) je tvořen do mřížky poskládanými spektry původní funkce s roztečemi $\frac{1}{\Delta x}$ a $\frac{1}{\Delta y}$. Dokážeme zrekonstruovat původní funkci pouze pokud se nám jednotlivá spektra neslijí a to platí jen pokud je původní funkce frekvenčně omezená a vzorkujeme s dostatečnou frekvencí:

$$\Delta x \leq \frac{1}{2W_u} \text{ a } \Delta y \leq \frac{1}{2W_v}, \text{ kde } W_u \text{ a } W_v \text{ jsou maximální frekvence v základních směrech.}$$

Potřebujeme dvakrát vyšší frekvenci než je maximální přítomná frekvence v původní fci.

Negativní projevy podvzorkování

- aliasing (stráta vysoko frekvenční informace — hrany, detaily)
- Moiré efekt — falešné nízké frekvence

Kvantování

- Diskretizace oboru hodnot signálu — vždy ztrátové.
- Často se kvantizér navrhuje tak aby využíval vlastnosti lidského oka — např. nerozlišitelným jasovým úrovním se přiřazuje stejná hodnota

25.5 Změna kontrastu a jasu

- ekvalizace histogramu
- převodní funkce pro jasové úrovně (LUT — lookup table)
- gamma korekce

25.6 Odstranění šumu

Šum sa vyčísluje ako logaritmus pomeru signálu k šumu v decibeloch dB (Signal-to-Noise Ratio). Čím viac decibelov tým lepší odstup signálu od šumu -> kvalitnejší obraz.

$$\text{SNR} = 10 \log \frac{D(f)}{D(n)} [\text{dB}]$$

\underline{f} — signál, \underline{n} — šum

Modely šumu:

- Aditivní náhodný šum $g = f + n$
- Gaussovský bílý šum
- Impulsní šum (sůl a pepř)

Noise reduction: (nedám za to ruku do ohňa)

- bílý šum -> Priemerovanie v čase (prosté/vážené)
- impulsní šum -> Mediánový filter (pre pixel vyberáme intenzitu medianu v okolí), iné nelineárne filtre,
- low-pass filter (napr. Gauss) — zbaví vysokofrekvenčného šumu (rovnako ako aj každej inej vysokofrekvenčnej informácie — hrany)
- Rotujúce okno — pokus o odstranenie vysokofrekvenčného šumu a zachovania hran zároveň. Može vytvárať artefakty.
- Priemerovanie podél hran

25.7 Detekce hran

Lidské vnímání je založeno na detekci hran (edge detection), tedy změnou jasu hrany vidíme objekty. Toho se také ve velké míře používá v segmentačních technikách pro zpracování obrazu. Mnoho metod segmentace právě vychází z detekce hran pro odlišení objektů v obraze. Hranu v obraze je charakterizovat gradientem, tedy velikostí a směrem. Existuje také mnoho filtrů pracujících s detekcí hran v obraze a hrany hrají také klíčovou roli pro příznaky a posléze klasifikace podle vektorů příznaků. Mezi geometrické příznaky patří např. pravoúhlost, podlouhlost, kruhovost či vzdálenost pixelů od okraje, tedy hrany. Vektor příznaků, označme jej např. $vc = (x_1, x_2, \dots, x_n)$, kde x_i je daný příznak. Tyto příznaky pak slouží jako vstupy (např. pro perceptron), a pomocí nich se klasifikuje výstup (třída).

25.8 Inverzní a Wienerův filtr

Předpokládáme, že známe funkci, která poškodila obraz.

Ideální případ — bez šumu:

$$g(x, y) = (f * h)(x, y), \text{ kde } h \text{ je funkce poškození, prostorově neměnná (stejná pro celý obraz).}$$

Z Convolution theoremu dostaneme:

$$\begin{aligned} G &= F \cdot H \\ F &= G \cdot \frac{1}{H} \end{aligned}$$

V praxi je však běžně přítomen i šum, který dekonvoluci stěžuje:

$$g(x, y) = (f * h)(x, y) + n(x, y), \text{ kde } n \text{ je aditivní šum, nezávislý na obrazové fci.}$$

$$\begin{aligned} G &= F \cdot H + N \\ F &= G \cdot \frac{1}{H} - \frac{N}{H} \end{aligned}$$

Z posledního výrazu je vidět, že šum bude nejvíce ovlivňovat výsledek na frekvencích, kde bude H téměř nulové.

Wienerův filtr

Wienerův filtr se snaží vypořádat se šumem a najít nejlepší opravu obrazu z hlediska nejmenších čtverců (matematicky správné, ale neideální pro člověka)

$$H_W(u, v) = \frac{H^*(u, v)}{|H(u, v)|^2 + \frac{S_{nn}(u, v)}{S_{ff}(u, v)}}$$

25.9 Určení vzájemné polohy snímků, problém korespondence bodu a objektu

25.10 Detekce hranic objektů, detekce oblastí

25.11 Příznaky pro popis a rozpoznávání 2D objektů, momentové invarianty

25.12 Wavelety a jejich použití

<http://users.rowan.edu/~polikar/WAVELETS/WTtutorial.html>

<http://pagesperso-orange.fr/polyvalens/clemens/wavelets/wavelets.html>

<http://cnx.org/content/m11140/latest/>

25.13 Statistická teorie rozpoznávání, klasifikace s učením (Bayessův, lineární a k-NN klasifikátor), klasifikace bez učení (hierarchické a iterační shlukování)

25.14 Počítačové vidění

25.15 Úvod do počítačové robotiky, plánování cesty mobilního robota

25.16 Předměty

- Digitální zpracování obrazu
- Speciální funkce a transformace ve zpracování obrazu
- Rozpoznávání vzorů
- Úvod do mobilní robotiky
- Počítačové vidění a inteligentní robotika

25.17 Materiály

- Slajdy: Flusser J., Zitová B. <http://staff.utia.cas.cz/zitova/prednasky/>, Hlaváč V. <http://cmp.felk.cvut.cz/~hlavac/HlavacTeachPresentCz.htm>, Štanclová J. <http://www.ksi.mff.cuni.cz/~stanclova/>
- Flusser J., Zitová B., Image registration methods: a survey, AVČR <http://library.utia.cas.cz/prace/20030125.pdf>
- Gonzales R. C., Woods R. E., Digital Image Processing http://www.imageprocessingbook.com/index_dip2e.htm

For more details look freelance writing opportunities site.