

Snímanie obrazu a jeho vlastnosti

Sonka, Hlavac, Boyle: Image Processing, Analysis and Machine vision,
kapitola: The image, its representations and properties


Gonzales, Woods: Digital Image Processing
kapitola: Digital image fundamentals

Shapiro : Computer Vision



Kamera a snímanie obrazu

camera obscura (tmavá komora)


- First photograph due to Niepce (1816)
- First on record - shown below (1822)
- Basic abstraction is the pinhole camera



Light is all around us!




- Ak dáme film pred objekt nedostaneme zmysluplný obraz



- Bariéra blokuje väčšinu svetla
- Redukuje blurring

Conventional camera design ...




Ken Kay, 1969 in "Light & Film", TimeLife Publ.


Vel'kost' strbiny a difrakcia svetla



Šošovky



- Sústredujú viac svetelných lúčov z každého bodu scény



- Iba objekty v správnej vzdialenosti sa zobrazia na film zaostrené (in focus)
- Iné objekty sa zobrazia do tzv. circle of confusion nezaostrený bod
- Zmenou tvaru šošovky meníme vzdialenosť zaostrenia (focus)

Proces snímání obrazu




Figure 2.1: Reflection of radiation received from a single source of illumination.

Základy projektívnej geometrie

- V projektívnej geometrii pracujeme s dvojrozmerným obrazom trojrozmerného sveta.
- Údaje ktoré spracovávame sú získane pomocou kamery, ktorá používa **perspektívnu projekciu** (**stredové premietanie**).
- Pri premietaní nie je jednoduché zistiť presnú polohu bodov, keďže viaceré body sa môžu premietnuť do toho istého bodu.

- Pozrime sa ktoré body to vlastne budú.
- Ak počiatok premietania je bod T a premietaný bod je bod X a premietame na rovinu R.
- Potom všetky body na polpriamke TX sa premietnu do toho istého bodu do roviny R.
- Formálny zápis:
- Majme $(n+1)$ -rozmerný priestor R^{n+1} , ktorý neobsahuje počiatok

$$\begin{aligned} [x_1, \dots, x_{n+1}]^T &\equiv [x'_1, \dots, x'_{n+1}]^T \text{ iff} \\ \exists \alpha \neq 0 : [x_1, \dots, x_{n+1}]^T &= \alpha [x'_1, \dots, x'_{n+1}]^T \end{aligned} \quad (9.1)$$

- Paralelne čiary nezostanú paralelne v perspektívnom obraze, napr. koľajnice




Figure 9.2 *Perspective projection of parallel lines.*

Homogénne súradnice

- Nech P je projektívny priestor
- Body v projektívnom priestore sú vyjadrené v homogénnych súradniciach
- One to one mapovanie je dané nasledovne

$$[x_1, \dots, x_n]^T \rightarrow [x_1, \dots, x_n, 1]^T \quad (9.2)$$

Geometria jednoduchéj perspektívnej kamery





Figure 9.3 The geometry of a linear perspective camera.

Počas premietania pracuje so 4 súradnicovými systémami a tými sú:

- svetový euklidovský súradnicový systém
- súradnicový euklidovský systém kamery
- súradnicový euklidovský systém premietacej roviny
- súradnicový afínny systém premietacej roviny


Svetový Euklidovský súradnicový systém

- Sú v ňom popísané body ktoré ideme premietat'
- teda X aj bod U sú zapísane v jeho súradniciach.
- Má počiatok v bode O (nejaký bod priestoru).
- Index w .



Súradnicový euklidovský systém kamery:


- Má počiatok v bode $C = O_c$ – ohniskový bod
- jeho z-ová os je rovnobežná s optikou osou,



- x-ová a y-ová os sú na ňu kolmé (ortogonálna báza)
- Existuje vzťah medzi kamerovým a svetovým systémom, ktorý sa dá vyjadriť transformáciou zloženou z posunutia t a rotácie R .

Obrazový euklidovský súradnicový systém


- Má rovnaké súradnicové osi ako kamerový súradnicový systém, ale posunuté do bodu O_i
- X_i a Y_i ležia v rovine obrazu



Obrazový afinný súradnicový systém

- Má osi u , v , w a počiatok v počiatku euklidovskej súradnicovej sústavy obrazu,

- v má smer ako Y_i a
- w má smer ako Z_i
- avšak u nemusí mať smer ako X_i .



- Zavádza sa preto, lebo pixle nemusia byť vo všeobecnosti kolmé a osi môžu byť škálované (ak by sme premietali, obraz by bol skosený a škálovaný)

Základný koncept

- Projektívna transformácia vo všeobecnom prípade môže byť rozdelená na 3 jednoduchšie transformácie, ktoré predstavujú prechody medzi jednotlivými súradnicovými systémami.
- **Projektívna rovnica** nám hovorí o tom, ako sa body z 3-rozmerného projektívneho priestoru premietajú do 2-rozmerného projektívneho priestoru.
- Majme bod X v priestore a chceme ho vyjadriť v súradnicovom systéme kamery, urobíme to nasledovne:

$$\mathbf{X}_c = \begin{bmatrix} x_c \\ y_c \\ z_c \end{bmatrix} = R (\mathbf{X}_w - \mathbf{t}) \quad (9.3)$$





Figure 9.4 Calculation of the co-ordinates of the projected point.

X_c je už bod z novými súradnicami, R je rotácia a t je posunutie kamery voči svetových súradníc. Bod X_c je premietnutý na plochu Π ako bod U_c

$$U_c = \left[\frac{-fx_c}{z_c}, \frac{-fy_c}{z_c}, -f \right]^T \quad (9.4)$$

Parametre R a t sa nazývajú vonkajšie kalibračné parametre kamery

- Teraz si zoberme bod U_0 , ktorý sa označuje ako **stred premietacej roviny**, jeho súradnice označme v afinnom súradnicovom systéme $(u_0, v_0, 0)$.
- jeho súradnice vieme ľahko získať



- v súradnicovom systéme kamery budú $(0,0,-f)$, potom vektor posunutia z U_0 do počiatku afinnej súradnicovej sústavy je $(-u_0, -v_0, 0)$.
- Keďže používame homogénne súradnice tak priemet bodu $u = [U, V, W]^T$ do 2-rozmerného euklidovského priestoru bude:

$$u = [u, v]^T = [U/W, V/W]^T.$$

- Afinné transformácie, ktoré nám hovoria o prechode zo súradnicovej sústavy kamery do afinity súradnicovej sústavy obrazu môžeme zapísať do matice, potom bude projektívna rovnica vyzerat' nasledovne:

$$\tilde{\mathbf{u}} = \begin{bmatrix} U \\ V \\ W \end{bmatrix} = \begin{bmatrix} a & b & -u_0 \\ 0 & c & -v_0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \frac{-fx_c}{z_c} \\ \frac{-fy_c}{z_c} \\ 1 \end{bmatrix} \quad (9.5)$$

- Parametre a , b , c nám hovoria o škálovaní a skosení pozdĺž súradnicových osí
- $-u_0$ a $-v_0$ nám hovoria o prechode od súradníc kamery k súradniciam premietania.
- Všetky tieto parametre sú kalibračné parametre a získavame ich pri kalibrácii kamery.

Aby sme odstránili parameter z_c tak ním vynásobíme rovnicu, dostaneme:

$$\begin{aligned} z_c \tilde{\mathbf{u}} &= z_c \begin{bmatrix} -fa & -fb & -u_0 \\ 0 & -fc & -v_0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \frac{x_c}{z_c} \\ \frac{y_c}{z_c} \\ 1 \end{bmatrix} = \begin{bmatrix} -fa & -fb & -u_0 \\ 0 & -fc & -v_0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_c \\ y_c \\ z_c \end{bmatrix} = \\ &= \begin{bmatrix} -fa & -fb & -u_0 \\ 0 & -fc & -v_0 \\ 0 & 0 & 1 \end{bmatrix} R(\mathbf{X}_w - \mathbf{t}) = K R(\mathbf{X}_w - \mathbf{t}) \end{aligned} \quad (9.6)$$

Matica K bude kalibračná matica kamery.

V tejto rovnici máme dva druhy parametrov závislých na kamere a to vonkajšie parametre a vnútorné parametre, vonkajšie parametre sú pozícia kamery v svetových súradniciach sú to 3 rotácie R a 3 translácie $\mathbf{t}$.

Uvažujme, že súradnicový systém kamery je totožný so súradnicovým systémom sveta, potom dostávame:

$$z_c \tilde{\mathbf{u}} = z_c \begin{bmatrix} U \\ V \\ W \end{bmatrix} = \begin{bmatrix} -fa & -fb & -u_0 \\ 0 & -fc & -v_0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_c \\ y_c \\ z_c \end{bmatrix} \quad (9.7)$$

Potom pre u a v po rozpísaní dostávame rovnice:

$$\begin{aligned} u &= \frac{U}{W} = -fa \frac{x_c}{z_c} - fb \frac{y_c}{z_c} - u_0 = \alpha_u \frac{x_c}{z_c} + \alpha_{shear} \frac{y_c}{z_c} - u_0 \\ v &= \frac{V}{W} = -fc \frac{y_c}{z_c} - v_0 = \alpha_v \frac{y_c}{z_c} - v_0. \end{aligned} \quad (9.8)$$

Týmto dostávame vnútorné parametre kamery a sú nimi:

α_u : hovorí o škálovaní v smere u

α_{shear} : hovorí o skosení v smere v

α_v : hovorí o škálovaní v smere v

u_0

v_0

Teraz si zoberme rovnicu 9.6,

$$\begin{bmatrix} -fa & -fb & -u_0 \\ 0 & -fc & -v_0 \\ 0 & 0 & 1 \end{bmatrix} R (\mathbf{X}_w - \mathbf{t}) = K \quad R (\mathbf{X}_w - \mathbf{t}) \quad (9.6)$$

pracujeme v homogénnych súradniciach tak súradnice bodu $\mathbf{X}_w$ budú $(x_w, y_w, z_w, 1)$, potom všetko vynásobíme a dostaneme rovnicu:

$$\tilde{\mathbf{u}} = \begin{bmatrix} U \\ V \\ W \end{bmatrix} = [KR \mid -K \quad R \mathbf{t}] \begin{bmatrix} \mathbf{X}_w \\ 1 \end{bmatrix} = M \begin{bmatrix} \mathbf{X}_w \\ 1 \end{bmatrix} = M \tilde{\mathbf{X}}_w \quad (9.9)$$

Matica M sa nazýva **projekčná matica**.

Kalibrácia kamery

Pri kalibrácii kamery môžeme buď vychádzať zo známej scény alebo z neznámej scény.

Pri neznámej scéne ak poznáme parametre pohybu kamery tak táto operácia je jednoduchá, zredukuje sa nám na nájdenie obrazu bodov vo viacerých obrázkoch.

Ak nepoznáme parametre kamery tak je toto komplikovaná úloha a nevieme scénu jednoznačne zrekonštruovať z jedného obrázku, potrebujeme aspoň 3 pohľady na scénu.

Pri známej scéne vieme parametre kamery získať priamo zo scény a kamera sa môže sama **nakalibrovat'**.

Bod sa premieta na rovinu nasledovne:

$$\alpha_j \tilde{\mathbf{u}}_j = M \begin{bmatrix} \mathbf{X}_j \\ 1 \end{bmatrix} \quad (9.11)$$

Rozpíšme si projekčnú rovnicu nasledovne:

$$\begin{bmatrix} \alpha u \\ \alpha v \\ \alpha \end{bmatrix} = \begin{bmatrix} m_{11} & m_{12} & m_{13} & m_{14} \\ m_{21} & m_{22} & m_{23} & m_{24} \\ m_{31} & m_{32} & m_{33} & m_{34} \end{bmatrix} \begin{bmatrix} x \\ y \\ z \\ 1 \end{bmatrix} \quad (9.12)$$

$$\begin{bmatrix} \alpha u \\ \alpha v \\ \alpha \end{bmatrix} = \begin{bmatrix} m_{11}x + m_{12}y + m_{13}z + m_{14} \\ m_{21}x + m_{22}y + m_{23}z + m_{24} \\ m_{31}x + m_{32}y + m_{33}z + m_{34} \end{bmatrix} \quad (9.13)$$

$$\begin{aligned} u(m_{31}x + m_{32}y + m_{33}z + m_{34}) &= m_{11}x + m_{12}y + m_{13}z + m_{14} \\ v(m_{31}x + m_{32}y + m_{33}z + m_{34}) &= m_{21}x + m_{22}y + m_{23}z + m_{24} \end{aligned} \quad (9.14)$$

máme 2 rovnice, každá s 12 neznámymi (x, y, z, m -ka, u, v),
to je 24 neznámych pre každý jeden bod.

Ak je k dispozícii n takých bodov dostaneme maticu tvaru
 $[2n \times 12]$


$$\begin{bmatrix} x & y & z & 1 & 0 & 0 & 0 & 0 & -ux & -uy & -uz & -u \\ 0 & 0 & 0 & 0 & x & y & z & 1 & -vx & -vy & -vz & -v \\ & & & & & & \vdots & & & & & \end{bmatrix} \begin{bmatrix} m_{11} \\ m_{12} \\ \vdots \\ m_{34} \end{bmatrix} = 0 \quad (9.15)$$

Matica M ma iba 11 neznámych parametrov

Na to aby sme teda vyriešili tento systém rovníc teda
potrebujeme aspoň 6 korešpondujúcich bodov.

Epipolar geometry

The epipolar geometry




C, C', x, x' and X are coplanar


The epipolar geometry

e, e' - epipoly
 u, u' - obrazy bodu x
 XCC' - epipolarna rovina
 l - vždy cez epipolu a u
 u' - nachádza sa na epipolárnej priamke

základná čiara -
pretína optické osi
v epipolách



prevádza dvojrozmerné hľadanie na jednorozmerné



Epipolar constraint

- Reduces correspondence problem to 1D search along an epipolar line

Kanonické stereo

- Kamery sa nachádzajú „vedľa seba“
- Priemetne ležia v jednej rovine
- Základňa je rovnobežná s horizontálnou súradnicovou osou súradnicových systémov kamier
- Rovnobežné optické osi
- Epipóly sa nepretínajú




Figure 9.9 The canonical stereo configuration where the epipolar lines are parallel in the image, and epipoles move to infinity.




Figure 9.10 *Elementary stereo geometry in canonical configuration.*

Poznámie

$2h$ – vzdialenosť medzi kamerami, pozícia ohnísk

f – ohnisková vzdialenosť

P_l, P_r - priemety bodu P

Chceme zistiť

z -ovú súradnicu bodu P

Kanonické stereo

Kamery: $z=0$


Využijeme podobnost' trojúhelníků

$$\frac{P_l}{f} = -\frac{h+x}{z} \quad (9.24)$$


$$\frac{P_r}{f} = \frac{h-x}{z} \quad (9.25)$$

$$z (P_r - P_l) = 2hf \quad (9.26)$$

$$z = \frac{2hf}{P_r - P_l} \quad (9.27)$$




The epipolar geometry




The camera baseline intersects the image planes at the epipoles e and e' . Any plane π containing the baseline is an epipolar plane. All points on π project on l and l' .

The epipolar geometry





Family of planes π and lines l and l'
Intersection in epipoles e and e'




Example: converging cameras




Example: motion parallel with image plane



Example: forward motion





$$\begin{aligned}
 \mathbf{u} &\simeq [K|0] \begin{bmatrix} \mathbf{X} \\ 1 \end{bmatrix} = K \mathbf{X}, \\
 \mathbf{u}' &\simeq [K'R | -K'R\mathbf{t}] \begin{bmatrix} \mathbf{X} \\ 1 \end{bmatrix} = K'(R\mathbf{X} - R\mathbf{t}) = K'\mathbf{X}' \quad (9.28)
 \end{aligned}$$

Vieme, že vektory $\mathbf{X}$, $\mathbf{X}'$ a $\mathbf{t}$ sú koplanárne. Zapišeme to rovnicou

$$\mathbf{X}_L^T \cdot (\mathbf{t} \times \mathbf{X}'_L) = 0 \quad (9.29)$$

Kamery

- Každá bunka v poli je fotosenzitívna dioda, ktorá konvertuje fotóny na elektróny
- Fotosenzitívna jednotka
 - CCD charge-coupled device
 - CMOS complementary metal oxide semiconductor
- Zachytávajú intenzitu svetla monochromatického obrazu




FIGURE 2.15 An example of the digital image acquisition process. (a) Energy (“illumination”) source. (b) An element of a scene. (c) Imaging system. (d) Projection of the scene onto the image plane. (e) Digitized image.

CCD kamera

- Posuvný register
- Zachytáva elektróny počas expozičného času
- elektróny transferuje postupne na okraj – výstupného zosilňovača
- Konvertované z analógového signálu na digitálny
- Má iba 1 výstup






Figure 1.22. A CCD Device.




CCD čip



Light Sensitive Area

- CCD replaces AgX film
- Based on *silicon chip*
- Disadvantages vs. AgX:
 - Difficulty/cost of CCD manufacture; large arrays are VERY expensive
 - “Young” technology; rapidly changing



CCD



Individual pixel element

Close-up of a CCD Imaging Array


Problémy CCD čipu

- Blooming
 - anti-blooming technology
- Nie je možné priamo pristupovať k jednotlivým pixelom
 - treba čítanie cez posuvný register

Farebný obraz

- Jednočipové CCD

- Farebné filtre – Bayerova maska



- Trojčipové CCD

- 3 CCD snímače – jemná optika – drahšie
 - Lúč prechádza cez optickú sústavu, ktorá láme svetlo na jednotlivé spektra



CMOS kamery

■ Výhody oproti CCD


- vyšší rozsah zachytených intenzít
- Vysoká rýchlosť čítania
- Random prístup k pixelom

■ Nevýhoda

- Vysoká úroveň šumu


Foveon X3

- CMOS obrazový senzor pre digitálne kamery
- Je schopný zaznamenať úplnú farebnú informáciu pre každý obrazový bod.
- Využíva vlastnosť, že rôzne vlnové dĺžky svetla prenikajú do rôznej hĺbky kremíkových vrstiev
- skladá sa z 3 vrstiev svetlocitlivých buniek kde každá zachytáva inú farebnú zložku svetla




Foveon X3 vs. Bayer

Foveon X3® Capture



A Foveon X3 direct image sensor features three separate layers of pixel sensors embedded in silicon.




Since silicon absorbs different wavelengths of light at different depths, each layer records a different color. Because the layers are stacked together, all three colors are captured.




As a result, only Foveon X3 direct image sensors capture red, green, and blue light at every pixel location.

Mosaic Capture



In conventional systems, color filters are applied to a single layer of pixel sensors in a tiled mosaic pattern.



The filters let only one wavelength of light—red, green, or blue—pass through to any given pixel location, allowing it to record only one color.



As a result, mosaic sensors capture only 25% of the red and blue light, and just 50% of the green.

CCD Array

- Photosensitive detector: **planar** silicon
- CCD: mega pixel (1,000 x 1,000 array).
- brightness range (at fixed exposure time) - 10^5 , actually encoded 10^2
- **uniform** spatial distribution
- colour images constructed from mosaic sensors
- CCD images have linear sensitivity (≈ 100 levels) and Gaussian noise

$$I(x, y) = i(x, y) \pm \sigma$$

Human Eye

- Photosensitive detector: **hemispherical** retina
- rods: 75- 150 million high sensitivity monochromatic receptors
- cones: 6-7 million low sensitivity colour receptors (in fovea)
- brightness range - 10^7 , actually encoded 10^5
- **non-uniform** spatial distribution
- The human eye has sensitivity to proportional differences (≈ 100 levels), i.e.:

$$S(x, y) = i(x_1, y_1) - i(x_2, y_2) \pm \gamma S(x, y)$$


Vlastnosti obrazu

- **Analógový obraz** je 2D obraz $F(x,y)$ s nekonečnou presnosťou parametrov x a y a nekonečnú presnosť intenzity v každom bode (x,y)
- **Digitálny obraz** je 2D obraz $I[r,c]$ reprezentovaný diskretným 2D poľom vzoriek intenzít, kde každá je reprezentovaná limitovanou presnosťou

- **Šedotónový obraz** (grey scale image) je monochromatický obraz $I[r,c]$ s jednou hodnotou intenzity pre každý pixel
- **Multispektrálny obraz** je 2D obraz $M[x,y]$ s vektorom hodnôt pre každý bod obrazu (farebný obraz – 3 hodnoty)
- **Binárny obraz** je digitálny obraz s hodnotami v pixeloch 0 alebo 1



RGB





Greyscale



Binary

Obraz ako funkcia




Digitalizácia obrazu


- Digitalizácia obrazu je **navzorkovanie (sampling)** spojitého obrazu do mriežky
- Mriežka je zvyčajne pravidelného tvaru štvorcové a hexagonálne
- Ďalším aspektom vzorkovania je nastavenie vzdialenosti medzi vzorkovanými bodmi
 - Čím menšia vzorkovacia vzdialenosť tým väčšie rozlíšenie



Scene



Grid over scene



Spatially sampled scene

- When a **continuous scene** is imaged on the array (grid) formed by a CCD , the continuous image is divided into discrete elements.
- The picture elements (*pixels*) thus captured represent a **spatially sampled** version of the image.

Typy mriežky

- 768x576 PAL
- 640x480 NTSC
- 1920x1080 HD





Figure 2.2: (a) Square grid. (b) Hexagonal grid.

- **Raster** je mriežka na ktorej sú definované susednosti

Susednosť a spojitost' pixlov

- 4-neighborhood
 - For pixel (i, j)
 $\{(i-1, j), (i+1, j), (i, j-1), (i, j+1)\}$
- 8-neighborhood
 - For pixel (i, j)
 $\{(i-1, j), (i+1, j), (i, j-1), (i, j+1)$
 $(i-1, j-1), (i+1, j+1), (i+1, j-1), (i-1, j+1)\}$


- Ak existuje cesta medzi ľubovoľným 2 obrazovými bodmi, tieto nazývame spojité



 4-neighbourhood of $\vec{x}$

 8-neighbourhood of $\vec{x}$

Paradox pretínajúcej čiary





- Obr. a: ak uvažujeme 4-spojitosť číary v ľavo nie sú spojené
- Obr. b: ak uvažujeme 8-spojitosť: čiara nepretína kruh lebo nemajú spoločný bod

Kvantizácia

- je prechod medzi spojitou hodnotou obrazovej funkcie a jej digitálnym ekvivalentom
- Kvantizácia na k rovnakých intervalov
- $k = 2^b$, b je počet bitov
- Malé k – vznikajú nepravé kontúry

Riešenie :

- Aspoň 100 úrovní šedej
- Rozdelenie na k nepravidelných intervalov
- Človek je schopný rozpoznať asi 60 odtieňov šedej







FIGURE 2.16 Generating a digital image. (a) Continuous image. (b) A scan line from *A* to *B* in the continuous image, used to illustrate the concepts of sampling and quantization. (c) Sampling and quantization. (d) Digital scan line.



a b

FIGURE 2.17 (a) Continuous image projected onto a sensor array. (b) Result of image sampling and quantization.

Problém priestorovej kvantizácie

0	0	0	0	0	0	0	0	0	0
0	8	0	0	0	0	8	8	0	0
0	0	0	0	0	0	8	8	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
8	8	8	8	8	8	8	8	8	8
0	0	0	0	0	0	0	0	0	0
8	8	8	8	8	8	8	8	8	8
8	8	8	8	8	8	8	8	8	8
0	0	0	0	0	0	0	0	0	0

(a)

2	0	0	4	0
0	0	0	4	0
4	4	4	4	4
4	4	4	4	4
4	4	4	4	4

(b)

0	0	0	0	0	0	0	0	0	0
0	8	0	0	0	0	8	8	0	0
0	0	0	0	0	0	8	8	0	0
0	0	0	0	0	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0
8	8	8	8	8	8	8	8	8	8
0	0	0	0	0	0	0	0	0	0
8	8	8	8	8	8	8	8	8	8
8	8	8	8	8	8	8	8	8	8
0	0	0	0	0	0	0	0	0	0

(c)

2	0	4	4
0	0	0	0
4	4	4	4
8	8	8	8

(d)

Figure 2.9: (a) 10×10 field of tiles of brightness 0 or 8. (b) Intensities recorded in a 5×5 image of precisely the brightness field at the left where each pixel senses the average brightness of a 2×2 neighborhood of tiles. (c) Image sensed by shifted camera “one tile down and one tile to the right”. Note that the quantized brightness values depend on both the actual pixel size and position relative to the brightness field. (d) Intensities recorded from the shifted camera in the same manner as in (b). Interpretation of the actual scene features will be problematic with either image (b) or (d).

Metriky

Euklidovská


$$D_e(p_1, p_2) = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}$$

City Block (Manhattan)


$$D_4(p_1, p_2) = |x_1 - x_2| + |y_1 - y_2|$$

Chessboard

$$D_8(p_1, p_2) = \max(|x_1 - x_2|, |y_1 - y_2|)$$



Original



Euklidovská




City block



Chessboard



Metriky



Euklidovská

$$d([i, j], [k, l]) = \sqrt{(i - k)^2 + (j - l)^2}$$



$$d = 5$$



Manhattan
(City-block)

$$d([i, j], [k, l]) = |i - k| + |j - l|$$


$$d = 7$$



Chessboard

$$d([i, j], [k, l]) = \max(|i - k|, |j - l|)$$

$$d = 4$$



Distance Transform

Operátor aplikovaný na binárne obrázky

0	0	0	0	0	0	1	0
0	0	0	0	0	1	0	0
0	0	0	0	0	1	0	0
0	0	0	0	0	1	0	0
0	1	1	0	0	0	1	0
0	1	0	0	0	0	0	1
0	1	0	0	0	0	0	0
0	1	0	0	0	0	0	0

Figure 2.8: Input binary image. Gray pixels correspond to objects and white pixels to background.

5	4	4	3	2	1	0	1
4	3	3	2	1	0	1	2
3	2	2	2	1	0	1	2
2	1	1	2	1	0	1	2
1	0	0	1	2	1	0	1
1	0	1	2	3	2	1	0
1	0	1	2	3	3	2	1
1	0	1	2	3	4	3	2

Figure 2.9: Result of the distance transform when the distance D_4 is considered in calculations.

Distance Transform












Figure 2.11: Illustration of four distances used often in distance transform calculations. The input image consists of three isolated 'ones'. The output distance is visualized as the intensity, lighter values denote higher distances. Contour plots are superimposed for better visualization. (a) Euclidean distance D_E . (b) City block distance D_4 . (c) Chessboard distance D_8 . (d) Quasi-Euclidean distance D_{QE} .

Distance Transform



Vnímanie obrazu - kontrast



Figure 2.17: Conditional contrast effect. Circles inside squares have the same brightness and are perceived as having different brightness values.

Vnímanie obrazu – vizuálne ilúzie




Figure 2.19: Disrupted parallel diagonal lines.





Figure 2.20: Horizontal lines are parallel, although not perceived as such.

Histogram


22 DEFINITION The **histogram** h of gray-tone image I is defined by

$$h(m) = |\{(r, c) \mid I(r, c) = m\}|,$$

where m spans the gray-level values.



a) Image of a bruised cherry





b) Histogram of the cherry image

Figure 3.22: Histogram of the image of a bruised cherry displaying two modes, one representing the bruised portion and the other the nonbruised portion. (Courtesy of Patchrawat Uthaisombut.)

Histogram


každéj úrovni jasů priradí zodpovedajúcu početnosť v obraze




vyhladenie histogramu



Vlastnosti histogramu

- Jasový histogram je globální deskriptor





Histogram stretching

$$g(x,y) = \frac{f(x,y)-f_{\min}}{f_{\max}-f_{\min}} * 2^{\text{bpp}}$$

- The formula requires finding the minimum and maximum pixel intensity multiply by levels of gray. If the image is 8bpp, so levels of gray are 256.


Histogram equalization

$$h(v) = \text{round} \left(\frac{cdf(v) - cdf_{min}}{(M \times N) - 1} \times (L - 1) \right)$$

- where cdf_{min} is the minimum non-zero value of the cdf,
- $M \times N$ gives the image's number of pixels (M is width and N the height) and
- L is the number of grey levels used (in most cases 256).




Before Histogram Equalization



Corresponding histogram (red) and cumulative histogram (black)



After Histogram Equalization



Corresponding histogram (red) and cumulative histogram (black)



Prahovanie histogramu

prahová (hraničná) hodnota: $p(i)$, $i=0,..n$

reprezentatívna farba: $f(i)$, $i=1,..n$ - voľba

$\forall$ body obrazu s intenzitou $I(x,y)$


$\forall i=1,..n$

ak $p(i-1) < I(x,y) \leq p(i)$ tak $I(x,y) = f(i)$




Prahovanie

adaptívne – hľadáme lokálne minimá




Výsledok





Prahovanie

pevný prah – pravidelné intervaly



Výsledok



Porovnanie

adaptívne vs. pevné



účel použitia



Impulse Noise

- Data loss or saturation
- Definitions

Salt noise:

DN = maximum possible

Pepper noise:

DN = minimum possible

Salt and pepper noise:

mixture of salt and
pepper noise


Line drop:

part or all of a line lost

pepper noise (0.05% and 2%)



Line drop





Structured Noise

- Periodic, stationary
 - ❖ Noise has fixed amplitude, frequency and phase
 - ❖ Commonly caused by interference between electronic components

simulation example

