


Mapovanie farebného rozsahu




tone mapping:

upravenie intenzity


gamut mapping:


upravenie farieb




Gamut = rozsah farieb, ktoré dokáže
zariadenie zobrazit', alebo rozsah farieb v
obrazu

Mapovanie gamutu:
Např. Prevod farieb
obrazu do farieb
zobraziteľných
tlačiarňou







COLOR FIGURE 1.24A




COLOR FIGURE 1.25A




COLOR FIGURE 1.24B



COLOR FIGURE 1.25B




COLOR FIGURE 1.24C



COLOR FIGURE 1.25C

Deskriptor hranice gamutu








Figure 3.1.5 Gamuts at primary and secondary hue angles in CIELAB.



Gamut mapping algoritmy

globálne GMA

Kompresia gamutu

Orezanie gamutu

lokálne GMA

Závisí od okolitých bodov

Zachováva detaily

J. Morovic, *To Develop a Universal Gamut Mapping Algorithm*. Derby, UK: University of Derby, PhD Thesis, 1998.


Typy mapovania

Orezanie gamutu

Mení body len mimo gamutu

Kompresia gamutu

Mení body aj vnútri




Orezanie

Ortogonalne
Radiálne

Horizontálne (C)


Vertikálne (L)





Kompresia

$$L^*_r = L^*_{r(\max)} - (L^*_{o(\max)} - L^*_o) * \frac{(L^*_{r(\max)} - L^*_{r(\min)})}{(L^*_{o(\max)} - L^*_{o(\min)})}$$


$$C^*_{s_r} = \begin{cases} C^*_{s_o} \frac{C^*_{g_{raL}}}{C^*_{g_{oaL}}}; C^*_{g_{oaL}} > C^*_{g_{raL}} \\ C^*_{s_o}; C^*_{g_{oaL}} \leq C^*_{g_{raL}} \end{cases}$$





Radiálna kompresia
L+C

Kvalita obrazu



Chyby obrazu	Možné príčiny
kontúrovanie	slabšia bitová hĺbka
blokovanie (blocking)	kompresia
zúbkovatosť (jaggies)	neprimeraná veľkosť pixla
kruhovanie (ringing)	zaostrenie, kompresia
optický klam (aliasing)	vzorkovanie
pruhovanie (streaking)	nejednotnosť odzvučenia
šablónovanie (patterning)	nižšie rozlíšenie, zlá kompresia
nesprávne zachytenie farby	obrázky zachytené z rôznych kanálov



<http://www.glitchet.com/resources>

<http://avaa.bavc.org/artifactatlas/>

Metriky

- $d(a, b) \geq 0$, pre $\forall a, b \in X$
- $d(a, b) = 0 \Leftrightarrow a = b$, pre $\forall a, b \in X$
- $d(a, b) = d(b, a)$, pre $\forall a, b \in X$
- $d(a, c) \leq d(a, b) + d(b, c)$, pre $\forall a, b, c \in X$

d – metrika

X – metrický priestor

Porovnanie odpovedajúcich si pixlov obrázkov

stredná kvadratická chyba

stredná absolútna chyba

L*a*b* chyba - ΔE

Chyba okolia

- Chyba v škálovom priestore

Minkowského metrika

$$\varepsilon^\gamma = \frac{1}{K} \sum_{k=1}^K \left\{ \frac{1}{N^2} \sum_{i,j=0}^{N-1} |C_k(i,j) - \hat{C}_k(i,j)|^\gamma \right\}^{1/\gamma}$$

MSE - stredná kvadratická chyba ($\gamma=2$)

MAE - stredná absolútna chyba ($\gamma=1$)

pre 1 kanál

$$MSE = \frac{1}{NM} \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} (A(i,j) - B(i,j))^2$$

$$MAE = \frac{1}{NM} \sum_{i=0}^{N-1} \sum_{j=0}^{M-1} |A(i,j) - B(i,j)|$$

Porovnanie zodpovedajúcich pixelov



RMSE 9.5



RMSE 5.2



Original bird



offset 1 pixel
(MSE = 230.7)



Original bird



Sinusoidal error
(MSE = 12.34)



offset 1 pixel
(MSE = 230.7)

$L^*a^*b^*$ chyba - ΔE

$$\Delta L^*(i,j) = L^*(i,j) - \hat{L}^*(i,j),$$

$$\Delta a^*(i,j) = a^*(i,j) - \hat{a}^*(i,j),$$



$$\Delta b^*(i,j) = b^*(i,j) - \hat{b}^*(i,j),$$

$$\frac{1}{N^2} \sum_{i,j=0}^{N-1} \sqrt{[\Delta L^*(i,j)^2 + \Delta a^*(i,j)^2 + \Delta b^*(i,j)^2]}$$

Chyba okolia

$$\min_1 = \min_{l,m \in w_{i,j}} \left\{ d \left(C(i,j), \hat{C}(l,m) \right) \right\}$$

$$\min_2 = \min_{l,m \in w_{i,j}} \left\{ d \left(\hat{C}(i,j), C(l,m) \right) \right\}$$



$$\sqrt{\frac{1}{2(N-W)^2} \sum_{i,j=W/2}^{N-W/2} [\min_1]^2 + [\min_2]^2}$$

SNR, PSNR

Signal to Noise Ratio

$$SNR \approx \frac{m}{\sigma}$$

$$SNR \text{ (dB)} = 10 \log_{10} \left(\frac{\sum_{i,j} x(i,j)^2}{\sum_{i,j} (x(i,j) - y(i,j))^2} \right)$$

Peak SNR

$$PSNR \text{ (dB)} = 10 \log_{10} \left(\frac{D^2 MN}{\sum_{i,j} (x(i,j) - y(i,j))^2} \right)$$



PSNR = 40 dB



PSNR = 30 dB



PSNR = 20 dB



PSNR = 10 dB



PSNR = 0 dB




additive
white noise



additive highpass
noise ("blue noise")

SNR = 10.00 dB




Korelácia

Normalizovaná korelácia 2 obrazov

Štrukturálny obsah

Czenakowského korelácia

Priemerný uhlový rozdiel



Normalizovaná korelácia 2 obrazov

$$\frac{1}{K} \sum_{k=1}^K \frac{\sum_{i,j=0}^{N-1} C_k(i,j) \hat{C}_k(i,j)}{\sum_{i,j=0}^{N-1} C_k(i,j)^2}$$

Priemerný uhlový rozdiel

$$1 - \frac{1}{N^2} \sum_{i,j=1}^N \left(\frac{2}{\pi} \cos^{-1} \frac{\langle C(i,j), \hat{C}(i,j) \rangle}{\|C(i,j)\| \|\hat{C}(i,j)\|} \right)$$


Czenakowského korelácia (pre striktne nenegatívne vektory)

Štruktúrálny obsah

$$\frac{1}{K} \sum_{k=1}^K \frac{\sum_{i,j=0}^{N-1} C_k(i,j)^2}{\sum_{i,j=0}^{N-1} \hat{C}_k(i,j)^2}$$

$$\frac{1}{N^2} \sum_{i,j=0}^{N-1} \left(1 - \frac{2 \sum_{k=1}^K \min(C_k(i,j), \hat{C}_k(i,j))}{\sum_{k=1}^K (C_k(i,j) + \hat{C}_k(i,j))} \right)$$

SSIM - Structural similarity index



Porovnanie

Intenzity

$$l(\mathbf{x}, \mathbf{y}) = \frac{2 \mu_x \mu_y + C_1}{\mu_x^2 + \mu_y^2 + C_1}$$

Kontrastu

$$c(\mathbf{x}, \mathbf{y}) = \frac{2 \sigma_x \sigma_y + C_2}{\sigma_x^2 + \sigma_y^2 + C_2}$$

$$s(\mathbf{x}, \mathbf{y}) = \frac{\sigma_{xy} + C_3}{\sigma_x \sigma_y + C_3}$$

$$\mu_x = \sum_{i=1}^N w_i x_i .$$

$$\sigma_x = \left(\sum_{i=1}^N w_i (x_i - \mu_x)^2 \right)^{1/2} .$$

$$\sigma_{xy} = \sum_{i=1}^N w_i (x_i - \mu_x)(y_i - \mu_y) .$$

$$\text{SSIM}(\mathbf{x}, \mathbf{y}) = [l(\mathbf{x}, \mathbf{y})]^\alpha \cdot [c(\mathbf{x}, \mathbf{y})]^\beta \cdot [s(\mathbf{x}, \mathbf{y})]^\gamma$$

$$\alpha = \beta = \gamma = 1$$

$$C_3 = C_2/2$$

$$C_1 = (0.01 * L)^2$$

$$C_2 = (0.03 * L)^2$$

$$L = 2^{\text{bits per pixel}} - 1$$

$$\text{SSIM}(\mathbf{x}, \mathbf{y}) = \frac{(2 \mu_x \mu_y + C_1) (2 \sigma_{xy} + C_2)}{(\mu_x^2 + \mu_y^2 + C_1) (\sigma_x^2 + \sigma_y^2 + C_2)}$$



(a)



(b)



(c)



(d)



(e)



(f)

(a) Original image (b) Contrast stretched image, $\text{MSSIM} = 0.9168$; (c) Mean-shifted, $\text{MSSIM} = 0.9900$; (d) JPEG compressed, $\text{MSSIM} = 0.6949$; (e) Blurred, $\text{MSSIM} = 0.7052$; (f) Salt-pepper noise, $\text{MSSIM} = 0.7748$.


Významné oblasti

Váhovanie chyby podľa výskytu vo významnej oblasti

1. Určenie významných oblastí
2. Určenie rozdielných pixlov
3. Váňovaná MSE alebo iná metrika



Detekcia a rozpoznávanie tvárí




Detekcia vs. Rozpoznávanie

Detekcia – klasifikácia do 2 tried

Tvár vs. Nie-tvár

Rozpoznanie – klasifikácia do viacerých tried

Osoba A vs. Ostatné osoby



- Detekcia = nájdenie všetkých tvárí, tvárových črt (oči, ústa, ...)
- Lokalizácia = detekcia jednej tváre
- Rozpoznanie, identifikácia = nájdenie zhody v databáze
- Autentifikácia = porovnanie s určitou tvárou (overenie ID), rozpoznanie veku, ...
- Sledovanie = časový sled tvárí, póz, ...
- Rozpoznanie výrazu = určenie emocionálneho stavu, ...

Detekcia

Je na obrázku tvár?
Ak áno, kde presne?



Problémy

Rotácia okolo osi z: frontálna, 45°, profilová fotka

Rotácia okolo osi y

Tvárové prvky: brada, fúzy
okuliare, ...

Výraz tváre

Zakrytie časti tváre:
ruka, vlasy, ...

Kvalita obrazu:

- Veľkosť


- Osvetlenie

- Distortion

- Šum

- Kompresia





Prístupy k detekcii

- 1) Znalostné metódy:
Čo tvorí typickú tvár?
napr. vzťah medzi črtami tváre
- 2) Metódy založené na invariantnosti:
Ktoré črty, ktoré príznaky sa nemenia v každej póze, osvetlení, ...?
- 3) Prikladanie šablón:
Štandardné vzory popisujúce tvár alebo črty tváre
- 4) Podobnostné metódy:
Modely založené na podobnosti tvárí, naučené z tréningových obrazov

TABLE 1
Categorization of Methods for Face Detection in a Single Image

Approach	Representative Works
Knowledge-based	Multiresolution rule-based method [170]
Feature invariant	
– Facial Features	Grouping of edges [87] [178]
– Texture	Space Gray-Level Dependence matrix (SGLD) of face pattern [32]
– Skin Color	Mixture of Gaussian [172] [98]
– Multiple Features	Integration of skin color, size and shape [79]
Template matching	
– Predefined face templates	Shape template [28]
– Deformable Templates	Active Shape Model (ASM) [86]
Appearance-based method	
– Eigenface	Eigenvector decomposition and clustering [163]
– Distribution-based	Gaussian distribution and multilayer perceptron [154]
– Neural Network	Ensemble of neural networks and arbitration schemes [128]
– Support Vector Machine (SVM)	SVM with polynomial kernel [107]
– Naive Bayes Classifier	Joint statistics of local appearance and position [140]
– Hidden Markov Model (HMM)	Higher order statistics with HMM [123]
– Information-Theoretical Approach	Kullback relative information [89] [24]

1) Znalostné metódy


Prístup zhora-nadol:

Tvár reprezentovaná pravidlami popisujúcimi črty tváre a ich vzťahy

Príklad:


Významný rozdiel medzi priemernou intenzitou strednej a hornej časti tváre

Tvár má väčšinou 2 oči umiestnené symetricky, nos v strede, ústa, ...




Tieto pravidlá riadia proces hľadania

Frontálny obraz tváre veľmi podobný pre všetkých, najmä pri nízkom rozlíšení



• Horizontálne/vertikálne projekcie



2) Invariantné príznaky


Prístup zdola-nahor:

Črty tváre (oči, nos, ústa ...)


Pomocou príznakov: hrany, intenzita, tvar, textúra, farba, ...

Kombinácia črt do skupín, overenie či skupina tvorí tvár


Correct Constellation



Random Constellation



- Facial features must occur in a specific spatial arrangement.
- Form constellations from the candidate feature locations.
- Find constellation that have the appropriate structure.



Given two feature positions, locations and the amount of uncertainty of the others can be estimated.


Detekcia pokožky

Farba kože – kompaktný zhuk vo farebnom priestore
Používané priestory

RGB, HSV, HIS, YCrCb, YIQ, YES, CIE XYZ, ...

Histogram, Gaussovský model, zmes Gaussiánov, ...

- if $p(\text{skin}|\mathbf{x}) > \theta$, classify as skin
- if $p(\text{skin}|\mathbf{x}) < \theta$, classify as not skin
- if $p(\text{skin}|\mathbf{x}) = \theta$, choose classes uniformly and at random



Statistical color model
M.J. Jones and J. Rehg



3) Prikladanie šablón

Šablóna

pevná: hrany, regióny

deformovateľná: kontúry

Šablóny sú dané,
nevedia sa učiť



4) Podobnostné metódy

Neurónové siete

PCA (analýza hlavných komponentov)


SVM (mechanizmy podporných vektorov)

Bayes

HMM (skryté Markovove modely)

Adaboost

...



Klasifikátory

Pozitívne príklady:

Zachytenie variácie v dátach

Ručné vystrihnutie tváre, normalizácia na jednotnú veľkosť (napr. 19×19)



Negatívne príklady:

Ľubovoľný obrázok neobsahujúci tvár



4) Metóda Viola/Jones

Real-time detekcia

Pomalý tréning

Hlavné myšlienky

Integrálne obrazy – rýchle vyhodnotenie príznakov

Boosting – výber príznakov/klasifikátorov


Kaskády – rýchle odmietnutie ne-tvárových vzoriek

P. Viola and M. Jones. *Rapid object detection using a boosted cascade of simple features*. CVPR 2001.

1. Tréning – algoritmus deteguje tvár v štvorcovom okne pevnej veľkosti

- jednoduché obdĺžnikové príznaky
- výber príznakov AdaBoost algoritmom

2. Klasifikácia – skenovanie obrazu v rôznych škálach pevným oknom




<https://www.youtube.com/watch?v=hPCTwxF0qf4>

Obdĺžnikové príznaky

Príznak $f(x) =$

$$\sum (\text{body v bielej oblasti (R2)}) - \sum (\text{body v čiernej oblasti (R1)})$$




Príznak $\equiv$ slabý klasifikátor tváre

$$h(x) = \begin{cases} 1 & \text{ak } f(x) > \theta \\ -1 & \text{inak} \end{cases}$$


Pre každý príznak iný prah


Integrálne obrazy



Suma bodov vľavo hore



- Suma bodov v obdĺžnikovom okne (ABCD) pôvodného obrazu =
$$IO(A) - IO(B) - IO(C) + IO(D)$$







Príznak $f(x) =$

$$\sum (\text{body v bielej oblasti (R2)}) - \sum (\text{body v čiernej oblasti (R1)})$$

$$= IO(A) - 2 IO(B) + IO(C) - IO(D) + 2 IO(E) - IO(F)$$

Boosting

Kombinácia slabých klasifikátorov do silnejšieho


Slabý klasifikátor – presnosť o málo lepšia než náhodná klasifikácia

$$ht(x) = \{-1, 1\}$$

Silný klasifikátor


Boosting

Slabý klasifikátor 1




Boosting

Zvýšenie váh




Boosting




Boosting

Zvýšenie váhy




Boosting

Slabý klasifikátor 3



Boosting

Výsledný klasifikátor – lineárna kombinácia slabých klasifikátorov



AdaBoost algorithmus

- Given example images $(x_1, y_1), \dots, (x_n, y_n)$ where $y_i = 0, 1$ for negative and positive examples respectively.
- Initialize weights $w_{1,i} = \frac{1}{2m}, \frac{1}{2l}$ for $y_i = 0, 1$ respectively, where m and l are the number of negatives and positives respectively.
- For $t = 1, \dots, T$:

1. Normalize the weights,

$$w_{t,i} \leftarrow \frac{w_{t,i}}{\sum_{j=1}^n w_{t,j}}$$

so that w_t is a probability distribution.

2. For each feature, j , train a classifier h_j which is restricted to using a single feature. The error is evaluated with respect to w_t , $\epsilon_j = \sum_i w_i |h_j(x_i) - y_i|$.
3. Choose the classifier, h_t , with the lowest error ϵ_t .
4. Update the weights:

$$w_{t+1,i} = w_{t,i} \beta_t^{1-e_i}$$

where $e_i = 0$ if example x_i is classified correctly, $e_i = 1$ otherwise, and $\beta_t = \frac{\epsilon_t}{1-\epsilon_t}$.

- The final strong classifier is:

$$h(x) = \begin{cases} 1 & \sum_{t=1}^T \alpha_t h_t(x) \geq \frac{1}{2} \sum_{t=1}^T \alpha_t \\ 0 & \text{otherwise} \end{cases}$$


where $\alpha_t = \log \frac{1}{\beta_t}$

Kaskády




Na začiatku klasifikátory odstránia čo najviac negatívnych vzoriek

Pozitívne klasifikované vzorky postupujú do ďalších (komplexnejších) klasifikátorov

Negatívna klasifikácia znamená okamžité vyradenie vzorky z ďalšej klasifikácie



Postupnosť klasifikátorov má
znižujúce sa množstvo falošne
identifikovaných tvárí



Tréning kaskády


Slabé klasifikátory: prah, aby sa minimalizovalo množstvo falošne negatívnych klasifikácií

Klasifikátory sú postupne trénované na falošne pozitívnych vzorkách predchádzajúcich klasifikátorov

K1 (1 príznak) – 100% detekcia + okolo 50% falošne pozitívnych vzoriek

K5 (5 príznakov) – 100% detekcia + 40% falošne pozitívnych vzoriek (20% kumulatívna chyba)

K20 (20 príznakov) – 100% detekcia + 10% falošne pozitívnych vzoriek (2% kumulatívna chyba)




Parametre:



Počet stupňov kaskády

Počet príznakov v každom stupni

Prah v každom klasifikátore



Haarove wavelety
24x24 aprox. 160000




Implementácia

24 x 24 okno

Škálovanie detektora, nie obrazov

Tvár môže byť detegovaná na viacerých prekryvoch
– postprocessing



Trénovacie dáta 4916x2 tvárí

Normalizované

Škálované na 24x24

Zrkadlené

10 000 nie-tvárí









38 stupňová kaskáda

1, 10, 25, 25, 50 ... příznaků v stupních

Celkový počet příznaků vo všechkých stupních
6061

MIT+CMU test set 130 obrazov s 507
tvárami





Detekcia profilu



