



Technical University of Cluj - Napoca
Computer Science Department

Pocesarea Imaginilor

Curs nr. 6

Prelucrari pe imagini multinivel (grayscale) (I)

Proprietati statistice ale imaginilor grayscale si aplicatii. Imbunatatirea calitatii imaginilor



Statistical features / Trasaturi statistice

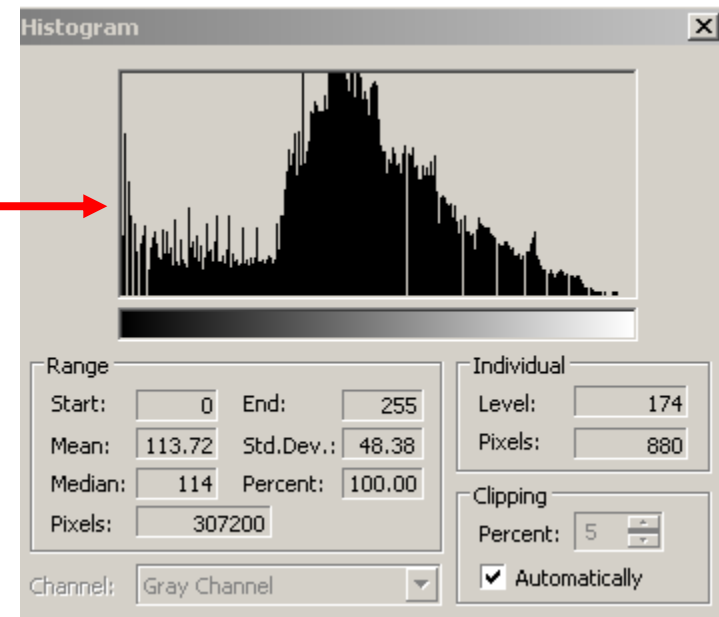
Trasaturi statistice \Rightarrow trasaturi globale (calculate pe intreaga imagine sau pe o regiune de interes – ROI)

Gray-levels histogram (histograma nivelurilor de gri/intensitate)

Nivele de gri: $g \in [0 \dots L]$, L – nivelul max. (imagini 8biti/pixel : $L=255$)

$$h(g)=N_g$$

N_g – numarul de pixeli din imagine/ROI care au nivelul de intensitate egal cu g





Statistical features / Trasaturi statistice

Probability distribution function (of the gray-levels)

(functia distributiei de probabilitate a nivelurilor de gri)

$P(g)$:= probabilitatea ca nivelul de intensitate dintr-o regiune sa fie mai mica sau egala cu g :

$$0 \leq P(g) \leq 1$$

$$P(g) - \text{monoton crescatoare} \Rightarrow dP/dg \geq 0$$

Probability density function (of the gray-levels): $p(g)$

(functia densitatii de probabilitate a nivelurilor de gri)

$p(g)\Delta g$:= probabilitatea ca nivelul de intensitate dintr-o regiune sa fie cuprins intre g si $g+\Delta g$

$$p(g) \cdot \Delta g = \left(\frac{dP(g)}{dg} \right) \Delta g$$

$p(g)$ – histograma normalizata:

$$p(g) = \frac{h(g)}{M}, \quad \text{with: } \begin{cases} p(g) \geq 0 \\ \int_{-\infty}^{\infty} p(g) dg = 1, \quad \sum_{g=0}^L \frac{h(g)}{M} = \frac{M}{M} = 1 \end{cases}$$

$M = \text{image_height} \times \text{image_width}$




Statistical features / Trasaturi statistice

Mean (media)


⇒ Masura a intensitatii medii dintr-o imagine / ROI

$$\bar{g} = \mu = \int g \cdot p(g) dg = \sum_{g=0}^L g \cdot p(g) = \frac{1}{M} \sum_{g=0}^L g \cdot h(g) = \frac{1}{M} \sum_{i=0}^{H-1} \sum_{j=0}^{W-1} I(i, j)$$

Image
"intunecata"



Imagine
"luminoasa"





Aplicatie: segmentare imagini grayscale

Basic global thresholding algorithm

- Calculeaza automat pragul de binarizare (T)
- Se poate aplica pe imagini cu histograma bimodala

Algoritmul

1. Take an initial value for T :

$$T_0 = \mu \text{ (object area = background area)}$$

$$T_0 = (g_{MAX} + g_{MIN})/2$$

2. *Step k*: segment the image after T_{k-1} by dividing the image pixels in 2 groups:



$$G1: I[i,j] < T_{k-1} \Rightarrow \mu_{G1}$$

$$G2: I[i,j] > T_{k-1} \Rightarrow \mu_{G2}$$

3. $T_k = (\mu_{G1} + \mu_{G2})/2$

4. Repeat 2-3 until $T_k - T_{k-1} < \varepsilon$

Implementare eficienta \Rightarrow se va calcula mai intai histograma imaginii iar apoi toate calculele (μ_{G_i}) se vor face pe histograma !!!






Statistical features / Trasaturi statistice

Standard deviation (deviatia standard)

⇒ Masura a contrastului mediu al imaginii / ROI

$$\sigma = \sqrt{\sum_{g=0}^L (g - \mu)^2 \cdot p(g)} = \sqrt{\frac{1}{M} \sum_{i=0}^{H-1} \sum_{j=0}^{W-1} (I(i, j) - \mu)^2}$$

Contrast ridicat



Contrast scazut






Image enhancement / Imbunatatirea calitatii imaginilor

Histogram slide / deplasarea histogramei

$$\text{Slide}(I[i,j]) = I[i,j] + \text{offset}$$

$\text{offset} > 0 \Rightarrow$ imagine mai “luminoasa”
 $\text{offset} < 0 \Rightarrow$ imagine mai “intunecata”









Image enhancement / Imbunatatirea calitatii imaginilor

Histogram stretch/shrink (latire/ingustare a histogramei)

$$\text{Stretch/Shrink}(I[i,j]) = \text{Final}_{\text{MIN}} + (\text{Final}_{\text{MAX}} - \text{Final}_{\text{MIN}}) * (I[i,j] - g_{\text{MIN}}) / (g_{\text{MAX}} - g_{\text{MIN}})$$



shrink →



← stretch



shrink →



← stretch



Image enhancement / Imbunatatirea calitatii imaginilor

Re-maparea nivelelor de gri folosind o functie de transformare

$$g_{\text{output}} = T(g_{\text{input}})$$

Ex. - gamma correction:

$$g_{\text{out}} = c \cdot g_{\text{in}}^{\gamma} \quad \text{sau} \quad \frac{g_{\text{out}}}{L} = c \cdot \left(\frac{g_{\text{in}}}{L} \right)^{\gamma}$$

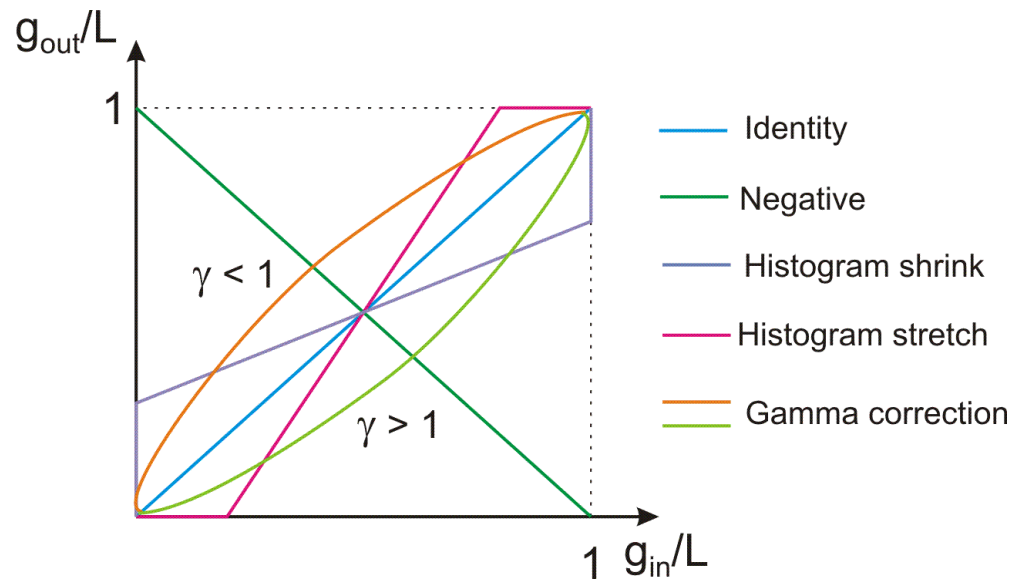





Image enhancement / Imbunatatirea calitatii imaginilor


Ex. - gamma correction:



$\gamma < 1$: codificare/compresie gamma



$\gamma > 1$: decodificare/decompresie gamma





Statistical features / Trasaturi statistice

Informatia – informatia asociata nivelului de intensitate g :

$$I_g = -\log_2 p(g) \quad [bits]$$

⇒ informatia este ridicata cand este generat un nivel de gri cu probabilitate mica

Entropy – informatia medie din imagine:

$$H = -\sum_{g=0}^L p(g) \cdot \log_2 p(g) \quad [bits]$$

⇒ Cati biti avem nevoie pentru a codifica datele din imagine:

H (mare) – val. pixelilor sunt distribuite pe multe nivele de gri

$H_{\max} = \log_2 L$ [bits] (uniform PDF)

Energy – cum sunt distribuite nivelele de gri:

$$E = \sum_{g=0}^L [p(g)]^2$$

E (mica) – numarul de nivele de gri este mare

$E_{\max} = 1$ (un singur nivel de gri)



Histogram equalization/ Egalizarea histogramei

Nivele de gri normalizate:


$$g \in [0 \dots L] \Rightarrow r \in [0 \dots 1]$$

Funcție de transformare:

$$s = T(r)$$

(a). Bijectiva si monoton crescatoare $\Rightarrow \exists r = T^{-1}(s)$



(b). $0 \leq T(r) \leq 1$





Histogram processing / Procesari pe histograma

Histogram equalization/ Egalizarea histogramei: rezultate





Histogram processing / Procesari pe histograma


Histogram equalization/ Egalizarea histogramei

- $p_r(r)$, $p_s(s)$ – FDP ale imaginii de intrare si iesire
- $p_r(r)$, $T(r)$ sunt cunoscute si T^{-1} satisface conditia (a)

$$p_s(s) = p_r(r) \left| \frac{dr}{ds} \right| \quad (1)$$

Historama cumulativa / FDP cumulativa (CDF)

$$s = T(r) = \int_0^r p_r(w) dw \quad (2)$$



T satisface (a) & (b)

Regula Leibniz: derivata unei integrale definite superior este chiar functia integrata evaluata in acea limita:

$$\frac{ds}{dr} = \frac{dT(r)}{dr} = \frac{d}{dr} \left[\int_0^r p_r(w) dw \right] = p_r(r) \quad (3)$$




Histogram equalization/ Egalizarea histogramei

(1) + (3) \Rightarrow

$$p_s(s) = p_r(r) \left| \frac{dr}{ds} \right| = p_r(r) \left| \frac{1}{p_r(r)} \right| = 1 \quad , \quad 0 \leq s \leq 1$$

$p_s(s)$:

- PDF uniforma
- independenta de $p_r(r)$



Algoritmul de egalizare a histogramei

$$p_r(r_k) = \frac{n_k}{n} \quad , \quad k = 0 \dots L, \quad r_k = k / L$$

$$s_k = T(r_k) = \sum_{j=0}^k p_r(r_j) = \sum_{j=0}^k \frac{n_j}{n} \quad , \quad k = 0 \dots L$$

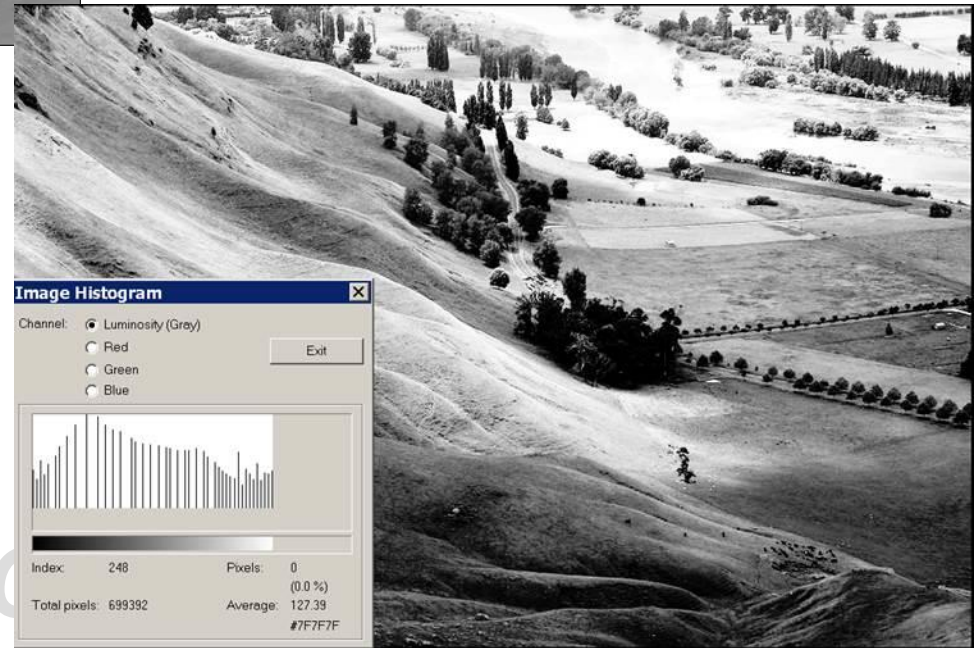
\Rightarrow remapare nivele de gri ale imaginii de iesire: $r_k \rightarrow s_k$



Egalizarea histogramei - exemplu




Egalizare





Histogram specification / matching (Specificarea histogramei)



input image

⇒

output image

Pentru imaginea de intrare :
$$s = T(r) = \int_0^r p_r(w)dw \quad (1)$$

Se defineste o variabila aleatoare z cu proprietatile:

$$G(z) = \int_0^z p_z(t)dt = s \quad (2)$$

$$(1) + (2) \Rightarrow G(z) = T(r)$$

$$z = G^{-1}(s) = G^{-1}[T(r)]$$



Histogram processing

Histogram specification / matching (Specificarea histogramei)

$$r_k \leftrightarrow z_k$$

Nu se poate deduce o expresie analitica pt. G^{-1} !?

Algorithm:

$$1. \quad r_k \leftrightarrow s_k: \quad s_k = T(r_k) = \sum_{j=0}^k p_r(r_j) = \sum_{j=0}^k \frac{n_j}{n}, \quad k = 0 \dots L$$


$$2. \quad z_k \leftrightarrow v_k: \quad v_k = G(z_k) = \sum_{j=0}^k p_z(z_j) = s_k, \quad k = 0 \dots L$$

$$3. \quad s_k \leftrightarrow z_k:$$

Fie $z' = z_k$, $k = 0, \dots, L$

z_k va fi cea mai mica valoare a lui z' care satisface conditia:

$$(G(z') - s_k) \geq 0$$






Metoda Otsu (calculul pragului de binarizare)

Definirea problemei

- Avem două grupuri de pixeli, care se întind pe domenii de intensități diferite (ex: obiecte și fundal). Problema selecției unui prag este complicată de faptul că aceste domenii de intensitate uneori se suprapun parțial. Se dorește minimizarea erorilor de clasificare a unui pixel obiect ca fundal, și viceversa.
- Pentru realizarea acestui deziderat, încercăm să minimizăm aria de sub histograma unei regiuni, care pe baza pragului calculat va fi atribuită celeilalte regiuni. Vom considera aceste două regiuni ca două grupuri.
- Pragul va fi ales astfel ca cele două grupuri să fie cât mai “strânse”, minimizând astfel suprapunerea.
- O măsură a omogenității grupului este varianța. Un grup cu omogenitate mare are o varianță mică, un grup cu omogenitate mică are varianță mare.



Metoda Otsu



Histograme de nivele de gri approximate prin două distribuții normale. Pragul se alege pentru a avea probabilitatea minimă de a segmenta greșit.

a) Distribuția de probabilitate a fundalului și a obiectelor

b) Histograma rezultată, și pragurile optime



Metoda Otsu

Varianța ponderată intra-clasă este: $\sigma_w^2(t) = q_1(t)\sigma_1^2(t) + q_2(t)\sigma_2^2(t)$

Probabilitățile asociate claselor sunt estimate ca: $q_1(t) = \sum_{i=1}^t P(i)$ $q_2(t) = \sum_{i=t+1}^I P(i)$
unde $P(i) = \frac{H(i)}{N^2}$

$$q_2 = 1 - q_1$$

Mediile claselor sunt definite ca: $\mu_1(t) = \sum_{i=1}^t \frac{iP(i)}{q_1(t)}$ $\mu_2(t) = \sum_{i=t+1}^I \frac{iP(i)}{q_2(t)}$

Varianțele individuale ale claselor sunt definite ca:

$$\sigma_1^2(t) = \sum_{i=1}^t [i - \mu_1(t)]^2 \frac{P(i)}{q_1(t)} \quad \sigma_2^2(t) = \sum_{i=t+1}^I [i - \mu_2(t)]^2 \frac{P(i)}{q_2(t)}$$

În acest moment avem toate ecuațiile necesare pentru a măsura varianța ponderată intra-clasă. Am putea să verificăm fiecare posibilă valoare a pragului t , și să o alegem pe cea care minimizează această varianță.

- Totuși, relația dintre varianța intra-clasă și varianța dintre clase se poate exploata pentru a găsi o recursivitate ce permite un calcul mai rapid.

Notatii: P – FDP, q – probabilitate ($q(t)$ – FDP cumulativa a lui P)



Metoda Otsu

Varianța totală a imaginii este:

$$\sigma^2 = \sum_{i=1}^I [(i - \mu)^2 P(i)] \quad \mu = \sum_{i=1}^I iP(i)$$

$$\sigma^2 = \sum_{i=1}^t [i - \underbrace{\mu_1(t) + \mu_1(t)} - \mu]^2 P(i) + \sum_{i=t+1}^I [i - \underbrace{\mu_2(t) + \mu_2(t)} - \mu]^2 P(i)$$

$$= \sum_{i=1}^t \{ [i - \mu_1(t)]^2 + 2[i - \mu_1(t)][\mu_1(t) - \mu] + [\mu_1(t) - \mu]^2 \} P(i)$$

$$+ \sum_{i=t+1}^I \{ [i - \mu_2(t)]^2 + 2[i - \mu_2(t)][\mu_2(t) - \mu] + [\mu_2(t) - \mu]^2 \} P(i)$$

Dar: $\sum_{i=1}^t [i - \mu_1(t)][\mu_1(t) - \mu]P(i) = 0$ $\sum_{i=t+1}^I [i - \mu_2(t)][\mu_2(t) - \mu]P(i) = 0$

Astfel $\Rightarrow \sigma^2 = \sum_{i=1}^t [i - \mu_1(t)]^2 P(i) + [\mu_1(t) - \mu]^2 q_1(t) + \sum_{i=t+1}^I [i - \mu_2(t)]^2 P(i) + [\mu_2(t) - \mu]^2 q_2(t)$

$$\sigma^2 = [q_1(t)\sigma_1^2(t) + q_2(t)\sigma_2^2(t)] + \{q_1(t)[\mu_1(t) - \mu]^2 + q_2(t)[\mu_2(t) - \mu]^2\}$$

$$\mu = q_1(t)\mu_1(t) + q_2(t)\mu_2(t) \quad 1 - q_1(t) = q_2(t)$$

$$\Rightarrow \sigma^2 = \sigma_w^2(t) + q_1(t)[1 - q_1(t)][\mu_1(t) - \mu_2(t)]^2$$



Metoda Otsu

Pentru orice prag, varianța totală a imaginii este suma dintre varianța intra-clasă, și varianța dintre clase.

$$\sigma^2 = \underbrace{\sigma_w^2(t)}_{\text{varianța intra-clasă}} + \underbrace{q_1(t)[1 - q_1(t)][\mu_1(t) - \mu_2(t)]^2}_{\text{varianța dintre clase}}$$

-Deoarece varianța totală este constantă, independentă de pragul t , efectul alegerii pragului este doar de a schimba ponderea celor două varianțe.

-Problema minimizării varianței intra-clasă este astfel echivalentă cu problema maximizării varianței dintre clase.

-Acest lucru se poate face recursiv.



Metoda Otsu

Inițializare: $q_1(1) = P(1) \quad ; \quad \mu_1(0) = 0$

Recursivitate: $q_1(t+1) = q_1(t) + P(t+1)$

$$\mu_1(t+1) = \frac{q_1(t)\mu_1(t) + (t+1)P(t+1)}{q_1(t+1)}$$

$$\mu_2(t+1) = \frac{\mu - q_1(t+1)\mu_1(t+1)}{1 - q_1(t+1)}$$

Pentru fiecare prag potențial t:

1. Se separă pixelii în două clase, pe baza pragului
2. Se calculează media celor două clase
3. Se calculează varianța dintre clase, conform ecuației de pe slide-ul anterior

Se reține pragul t care maximizează această varianță.

https://en.wikipedia.org/wiki/Otsu%27s_method



Aplicatie: segmentare imaginii grayscale

Metoda OTSU pt. praguri multiple:

G. X.Ritter, J.N. Wilson, Handbook of computer vision algorithms in image algebra - 2nd ed, 2001 CRC Press: Cap. 4.7. Threshold Selection by Maximizing Between-Class Variance.