

## 6.2 Prahové metódy

Patria k najstarším a najpoužívanejším metódam segmentácie obrazu. Sú najjednoduchšie, z čoho vyplýva ich výpočtová nenáročnosť a rýchlosť. Patria k metódam diskriminačnej analýzy.

Prahovanie využíva skutočnosť, že jednotlivé objekty a oblasti na obraze majú konštantnú odrazivosť a pohltivosť svojho povrchu. Na základe zvoleného *kritéria* sa snažíme určiť hraničnú hodnotu nejakého *príznaku* obrazu a podľa tejto hodnoty zatriedujeme obrazové body do oblastí.

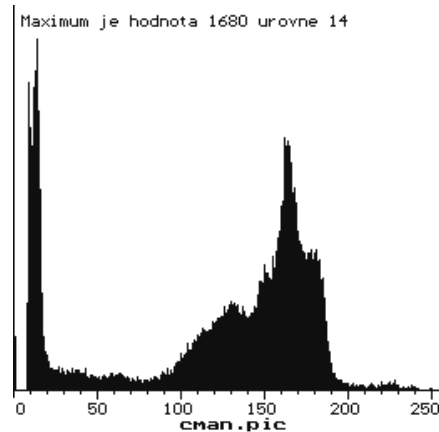
**Kritériom** môže byť zachovanie momentov obrazu, maximálna, prípadne minimálna entropia a v najjednoduchšom prípade veľkosť úrovne jasu.

**Príznak** je meraná charakteristika obrazu. V závislosti od voľby príznaku sa ďalej odvíja celý proces analýzy obrazu, preto je správny výber príznakov veľmi dôležitý. Pri rozhodovaní treba zohľadniť tieto skutočnosti:

- **diskriminačná účinnosť** – príznaky pre rôzne objekty musia mať podstatne odlišné vlastnosti,
- **spoľahlivosť** – príznaky pre tie isté objekty by mali mať tie isté alebo aspoň veľmi podobné vlastnosti,
- **nezávislosť** – potrebná je vzájomná nekorelovanosť príznakov,
- **malý počet** – zložitosť celého systému je priamo úmerná počtu príznakov.



(a)



(b)

**Obr. 6.1.** Príklad histogramu obrazu: a) originálny obraz 256 x 256 obrazových bodov, 256 úrovní jasu, b) histogram obrazu

Vo vytvorených oblastiach dochádza k nahradeniu pôvodnej hodnoty videosignálu v jednotlivých bodoch zvoleným znakom príslušnosti k oblasti. Takýmto znakom môže byť napríklad určitá úroveň jasu.

V najjednoduchšom prípade prahovanie vychádza z predstavy, že obraz obsahuje dva typy oblastí – objekt a pozadie, ktoré sú dostatočne odlišené úrovňou jasu. Za tohto predpokladu je určenie prahovej hodnoty jednoduchá úloha.

Nech  $f(n_1, n_2)$  je funkcia jasu obrazu. Obraz je definovaný na množine  $N$ , pričom funkcia  $f(n_1, n_2)$  nadobúda hodnoty  $(u_0, u_1, \dots, u_{L-1})$ , ktoré označujú úrovne jasu. Nech  $h(u)$  predstavuje histogram obrazu. **Histogram** je graf diskrétnych hodnôt početností jednotlivých úrovní jasu. Obraz a jeho histogram sú znázornené na obrázku 6.1. Histogram môže mať viaceré vrcholy – tzv. **dominantné módy**. Ak obraz pozostáva zo svetlých objektov na tmavom pozadí (resp. opačne), tieto sú charakterizované dvoma dominantnými módmi. Potom najjednoduchším výberovým kritériom je voľba takej jasovej konštanty  $t$ , ktorá separuje oba módy histogramu [GoWo82]. Pre svetlý objekt na tmavom pozadí ľubovoľný bod obrazu  $(n_1, n_2)$  bude patriť pozadiu, ak platí  $f(n_1, n_2) \leq t$ , alebo objektu, ak platí  $f(n_1, n_2) > t$ . Je to teda transformácia vstupného obrazu  $f(n_1, n_2)$  na výstupný binárny obraz  $g(n_1, n_2)$  podľa vzťahu

$$g(n_1, n_2) = \begin{cases} u_0 & \text{pre } f(n_1, n_2) \leq t \\ u_{l-1} & \text{pre } f(n_1, n_2) > t \end{cases} \quad (6.1)$$

Vo všeobecnosti je prahovanie založené na výbere optimálnej prahovej hodnoty  $t_0$  zo všetkých možných prahových hodnôt  $t$  výpočtom kritériálnej funkcie. Ak určenie prahovej hodnoty závisí výlučne od úrovni jasnosti v jednotlivých bodoch obrazu, hovoríme o **bodovo závislých metódach**. Ak je prah závislý aj od lokálnej vlastnosti (napr. rozloženie úrovni jasnosti) v okolí jednotlivých bodov obrazu, ide o **oblastne závislú metódu**. **Globálna prahová metóda** je taká, ktorá prahuje vstupný obraz jediným prahom, zatiaľ čo **lokálna prahová metóda** rozdeľuje daný obraz na časti a určuje prah pre každú časť zvlášť. Ak sa prahová hodnota jasnosti mení v závislosti od polohy bodu na obraze, metóda sa nazýva **dynamická**, prípadne adaptívna. Na tomto mieste treba spomenúť aj skupinu **metód viacúrovňového prahovania**, ktoré sú spravidla založené na niektorom z predchádzajúcich princípov, ale určujú viac prahových hodnôt na obraze.

Rozloženie úrovni jasnosti na obrazoch nemusí byť vždy také, že v histograme jasne vidieť dominantné módy. Často dochádza k ich prekryvaniu. Spôsobuje to premenlivosť úrovni jasnosti na povrchu objektov alebo pozadia. Môže byť zapríčinená napríklad nerovnomernosťou osvetlenia, nehomogenitou oblastí a pod. To má za následok porušenie modality histogramu. Prejaví sa to tým, že výrazné minimum medzi dominantnými módmi buď nemožno jednoznačne určiť, alebo vôbec neexistuje.

## Metóda diskriminačnej analýzy

Predpokladajme, že  $f(n_1, n_2)$  je funkciou jasu obrazu zloženého z dvoch oblastí – objektu a pozadia [GoWo82]. Nech  $h(u)$  je histogram tohto obrazu. Ak rozmer obrazu je  $N = n \times n$ , potom pre funkciu  $h(u)$  platí:

$$\sum_i h(u_i) = n^2 \quad \text{pre } i = (0, 1, \dots, l-1) \quad (6.2)$$

Definujme funkciu  $p(u)$  pre jednotlivé úrovne jasu  $u_i$ :

$$p(u_i) = \frac{h(u_i)}{n^2} \quad (6.3)$$

Platí

$$\sum_i p(u_i) = 1 \quad \text{kde } p(u_i) \geq 0 \text{ a } i = (0, 1, \dots, l-1) \quad (6.4)$$

Hodnota  $p(u_i)$  predstavuje pravdepodobnosť výskytu  $i$ -tej úrovne jasu na obraze. Funkciu  $p(u)$  môžeme považovať za odhad funkcie hustoty pravdepodobnosti úrovni jasu. Takto môžeme označiť aj odhad funkcie hustoty úrovni jasu objektu a pozadia. Nech je teda  $p_1(u)$  odhad funkcie hustoty pravdepodobnosti úrovni jasu objektu a  $p_2(u)$  pozadia. Funkcia  $p(u)$  je zrejme súčtom funkcií  $p_1(u)$  a  $p_2(u)$ . Ak má však platiť vzťah (4.4), musia byť funkcie  $p_1(u)$  a  $p_2(u)$  váhované, to znamená násobené koeficientmi, ktoré môžeme chápať ako normovanú mieru veľkosti objektu a pozadia. Nech týmito koeficientmi sú  $P_1$  a  $P_2$ , pričom platí  $P_1 + P_2 = 1$ . Potom

$$p(u) = P_1 \cdot p_1(u) + P_2 \cdot p_2(u) \quad (6.5)$$

Ak za prahovú hodnotu zvolíme úroveň jasu  $t$  ležiacu medzi dvoma maximami funkcie a zaradíme body obrazu do klasifikačných oblastí podľa predpisu pre binárne prahovanie, dopustíme sa chyby, pri ktorej určitý počet bodov patriaci do objektu bude

zaradený medzi body pozadia a naopak, niektoré body obrazu patriace pozadiu budú klasifikované ako body objektu. Veľkosť tejto chyby môže nadobúdať rozličné hodnoty v závislosti od polohy prahu  $t$ , čo môžeme vyjadriť vzťahom

$$\varepsilon(t) = P_1 \cdot \sum_{u=u_0}^t p_2(u) + P_2 \cdot \sum_{u=t+1}^{u_{l-1}} p_1(u) \quad (6.6)$$


Najlepšia hodnota prahu bude zrejme tá, pre ktorú funkcia (4.6) nadobúda minimum. Pre niektoré spojité funkcie, napríklad Gaussovo (normálne) rozdelenie pravdepodobnosti s parametrami  $\mu_1, \sigma_1$  a  $\mu_2, \sigma_2$  má chybová funkcia tvar

$$\varepsilon_S(t) = P_1 \cdot \int_{-\infty}^t p_2(u) \cdot du + P_2 \cdot \int_t^{\infty} p_1(u) \cdot du \quad (6.7)$$

Optimálna hodnota prahu  $t$  je riešením kvadratickej rovnice.

Ak budeme považovať  $p_i(u)$  za normálne rozdelenia pravdepodobnosti, hodnotou  $t$  je práve bod, v ktorom sa funkcie  $P_1 \cdot p_1(u)$  a  $P_2 \cdot p_2(u)$  pretínajú (**obr. 6.2**) a príklad výsledku segmentácie je na **obr. 6.3.(c)**.

V niektorých prípadoch môže byť výhodnejšie použitie Poissonovho rozdelenia pravdepodobnosti ( $Po(\square)$ ). Výsledok prahovania pre túto aproximáciu je ilustrovaný na **obr. 6.3.(a)**



**Obr. 6.2.** Priebehy funkcií pre Gaussovo rozloženie pravdepodobnosti: a)  $P_1 \cdot p_1(u)$ , b)  $P_2 \cdot p_2(u)$ , c)  $p(u)$ . Optimálna hodnota prahu  $t$  je bod, v ktorom sa funkcie  $P_1 \cdot p_1(u)$  a  $P_2 \cdot p_2(u)$  pretínajú.

Často nastáva prípad, keď sa módy histogramu natoľko prekrývajú, že nie je možné určiť minimum a parametre  $\mu_1$ ,  $\sigma_1$ ,  $\mu_2$ ,  $\sigma_2$ ,  $P_1$  a  $P_2$  nie sú známe. Môžeme spraviť odhad týchto parametrov. Jednou z možností je použitie **metódy minimalizácie chybnéj klasifikácie bodov obrazu na objekt a pozadie** (autori: J Kittler a J. Illingworth) [Kill86] tak, aby sme dosiahli čo najmenší rozdiel medzi vypočítanou hodnotou funkcie  $p(u)$  a jej odhadom.

## **Metóda minimalizácie chybnéj klasifikácie bodov obrazu na objekt a pozadie (autori: J Kittler a J. Illingworth)**

Prah získame minimalizáciou kritériálnej funkcie, ktorá nepriamo vyjadruje veľkosť prekrytia medzi dvoma normálnymi rozdeleniami objektu a pozadia – t.j. určíme **Bayesovo minimum**.

Histogram úrovní jasu obrazu aproximujeme normálnymi (Gaussovskými) rozdeleniami pravdepodobnosti:

$p(u/\gamma, t)$  s parametrami  $\mu_\gamma(t)$ ,  $\sigma_\gamma(t)$  a apriórnymi pravdepodobnosťami  $P_\gamma(t)$

$$p(u/\gamma, t) = \frac{1}{\sigma_\gamma \cdot \sqrt{2 \cdot \pi}} \cdot \exp \left[ -\frac{1}{2} \cdot \frac{(u - \mu_\gamma)^2}{\sigma_\gamma^2} \right] \quad (6.8.)$$

Pravdepodobnosť, že úroveň jasu je správne klasifikovaná, je daná vzťahom:

$$I(u, t) = \frac{p(u/\gamma, t) \cdot P_\gamma(t)}{p(u)} \quad \gamma = \begin{cases} 1 & u \leq t \\ 2 & u > t \end{cases} \quad (6.9.)$$

kde  $I(u, t)$  môžeme interpretovať ako index správnosti klasifikácie.



(a)  $t=64$



(b)  $t=88$



(c)  $t=26$



(d)  $t=80$

**Obr. 6.3** Porovnanie segmentovaných obrazov : (a) prahovanie-Bayesovo minimum – $P_0(\lambda)$ ,  $t=64$ , (b) metóda analýzy rozptylu - Otsu,  $t=88$ , (c) prahovanie-Bayesovo minimum – $N(\mu, \sigma)$ ,  $t=26$ , (d) vizuálna segmentácia,  $t=80$



## Metóda analýzy rozptylu

Táto metóda je pomerne jednoduchá a široko aplikovateľná, pretože na jej použitie stačí poznať iba hodnoty histogramu.

Predpokladajme, že úrovne jasů obrazu tvoria dva dominantné módy histogramu. V takomto prípade je jednoduché stanoviť prahovú hodnotu  $t$  a zatriediť úrovne jasů do dvoch skupín:

$$\mathbf{U}_1 = \{0, 1, \dots, t\}$$

$$\mathbf{U}_2 = \{t+1, t+2, \dots, u_{l-1}\}$$

Nech úrovne jasů z množiny  $\mathbf{U}_1$  reprezentujú objekt a úrovne jasů z množiny  $\mathbf{U}_2$  pozadie.

Označme

$$F_1(t) = \sum_i p(u_i) \quad i = (0, 1, \dots, t) \quad (6.10)$$

$$F_2(t) = \sum_i p(u_i) \quad i = (t+1, t+2, \dots, l-1) \quad \text{kde } F_2(t) = 1 - F_1(t) \quad (6.11)$$

Stredná hodnota a disperzia úrovni jasů v obraze, ako aj v množinách  $\mathbf{U}_1$  a  $\mathbf{U}_2$  nadobúdajú nasledovné hodnoty:

$$\mu = \sum_i u_i \cdot p(u_i); \quad \sigma^2 = \sum_i (u_i - \mu)^2 \cdot p(u_i); \quad i = (0, 1, \dots, l-1) \quad (6.12)$$

$$\mu_1(t) = \frac{1}{F_1(t)} \cdot \sum_i u_i \cdot p(u_i) \quad (6.13)$$

$$\sigma_1^2(t) = \frac{1}{F_1(t)} \cdot \sum_i (u_i - \mu_1(t))^2 \cdot p(u_i); \quad i = (0, 1, \dots, t) \quad (6.14)$$

(6.15)

$$\mu_2(t) = \frac{1}{F_2(t)} \cdot \sum_i u_i \cdot p(u_i)$$

$$\sigma_2^2(t) = \frac{1}{F_2(t)} \cdot \sum_i (u_i - \mu_2(t))^2 \cdot p(u_i); \quad i = (t+1, t+2, \dots, l-1) \quad (6.16)$$

Celková vnútorná disperzia  $\sigma_v^2(t)$  v oblastiach  $U_1$  a  $U_2$  je rovná

$$\sigma_v^2(t) = F_1(t) \cdot \sigma_1^2(t) + F_2(t) \cdot \sigma_2^2(t) \quad (6.17)$$

a pre medzitriednu disperziu  $\sigma_m^2$  platí

$$\sigma_m^2(t) = F_1(t) \cdot (\mu_1(t) - \mu)^2 + F_2(t) \cdot (\mu_2(t) - \mu)^2 \quad (6.18)$$

Vhodnou voľbou prahu bude zrejme taká hodnota  $t$ , v ktorej bude vnútorná disperzia objektu a pozadia nadobúdať minimum. Keďže

$$\sigma^2 = \sigma_v^2(t) + \sigma_m^2(t) \quad (6.19)$$

požiadavka minimalizácie vnútornej disperzie je rovnocenná s požiadavkou maximalizácie medzitriednej disperzie:

$$\sigma_m^2(t_0) = \max \sigma_m^2(t) \quad (6.20)$$

Hodnota  $t_0$  je optimálnou prahovou hodnotou pre klasifikáciu bodov obrazu na body objektu a body pozadia.

Na výpočte vnútornej, medzitriednej a celkovej disperzie obrazu je založená **metóda OTSU** [Otsu79].

Autor definoval tri rovnocenné kritériálne funkcie

$$J_{\lambda}(t) = \frac{\sigma_m^2(t)}{\sigma_v^2(t)} ; \quad J_{\eta}(t) = \frac{\sigma_m^2(t)}{\sigma^2} ; \quad J_{\chi}(t) = \frac{\sigma^2}{\sigma_v^2(t)} \quad (6.21)$$

Optimálnu prahovú hodnotu  $t_0$  určíme pomocou niektorej z nich. Najvhodnejšie je použiť funkciu  $J_{\eta}(t)$ , pretože **medzitriedna variácia** vyžaduje len výpočet štatistických momentov nultého a prvého rádu, a teda je najjednoduchšia (**Obr.6.3,b**). Metódu je možné rozšíriť na viacúrovňové prahovanie. Treba však poznamenať, že s narastajúcim počtom tried spoľahlivosť metódy klesá, pretože sa znižuje presnosť kritériálnej miery (medzitriedna disperzia). Navyše sa neúmerne zvyšuje výpočtová náročnosť.