

KAPITOLA 5 SEGMENTÁCIA OBRAZU

Jednou z dôležitých činností v rámci spracovania obrazu je analýza obrazu (Gonzalez, 1992, Schalkoff, 1989, Ružický, 1995). Jej cieľom je buď obraz popísať, alebo ho zaradiť do určitej triedy, teda klasifikovať ho na základe nejakej charakteristiky. Obraz môžeme analyzovať rôznymi spôsobmi. Základnú informáciu môžeme získať z mapy úrovni jasů na obraze a túto informáciu ďalej spracovávať postupne k informáciám "vyššej úrovne" - metóda zdola nahor, alebo opačne, predpokladáme určité špecifické charakteristiky a postupujeme smerom k charakteristikám nižšej úrovne, až kým nezískame mapu úrovni jasů spracovávaného obrazu - metóda zhora nadol. V praxi sa najčastejšie používa kombinácia oboch postupov (Šonka, 1992).

Súčasťou analýzy obrazu je segmentácia. Jej úlohou je spájať základné obrazové prvky do celkov - nositeľov vlastnej, novej informácie, tzv. informácie vyššej úrovne. Tieto celky môžu byť v ďalšej analýze obrazu použité ako nové základné obrazové jednotky. Segmentáciou sa teda jednotlivé časti obrazu identifikujú podľa určitých vlastností, ktoré sú pre ne spoločné.

Neexistuje všeobecne platná metóda, vhodná pre segmentáciu každého obrazu. Problém segmentácie obrazu má psycho-fyzický charakter, a teda neexistuje čisto analytické riešenie. Jedným z dôvodov, prečo neexistuje všeobecne platný systém je, že môžeme vytvoriť prakticky nekonečné množstvo dvojrozmerných obrazov a na ich správnu segmentáciu by sme potrebovali zozbierať a uschovať nekonečné množstvo podporných informácií. Každý matematický algoritmus musí byť podporený nejakými ďalšími, zvyčajne sémantickými charakteristikami triedy obrazov, pre ktoré je daná metóda vhodná.

Segmentácia obrazu nadobúda stále viac na význame. Nachádza uplatnenie v multimediálnych aplikáciách a stáva sa súčasťou kompresných metód (Martínez, 2000, Martínez, 2001, Ghanbari, 1999, Polec, 2000).

Rozdelenie metód segmentácie

Prvú veľkú triedu tvoria metódy segmentácie využívajúce *zhodnosť*, resp. *podobnosť* sledovaného príznaku na obraze. Patria sem:

- *prahové metódy* - vychádzajú z histogramu úrovni jasů obrazu, ktorý rozdeľujú prahovou hodnotou na úrovne jasů alebo farby objektu a pozadia na základe stanoveného kritéria,
- *metódy zhlukovej analýzy* - vytvárajú priamo oblasti, a to buď *štiepením* originálneho obrazu na homogénne celky, alebo *spájaním* elementárnych oblastí do väčších celkov na základe ich homogenity.

Ďalšia skupina využíva *rozdielnosť* skúmaného príznaku. Sú to

- *metódy detekcie hrán* medzi jednotlivými objektmi a pozadím na obraze.

V prípade, keď poznáme tvar objektov na obraze, sú vhodné

- *metódy segmentácie porovnávaním so vzorom*. Z jedného snímku vyčleníme hľadané objekty - vzory a pomocou vhodne zvoleného prehľadávania nájdeme rovnaké objekty na inom obraze.

Samostatné skupiny tvoria

- *metódy segmentácie textúrovňových obrazov* - rozdeľujú obraz na oblasti na základe vhodného opisu textúry štatistickými alebo štruktúrnymi charakteristikami,
- *metódy segmentácie pohyblivého obrazu* - využívajú rozdiely hodnôt v jednotlivých bodoch obrazu na snímkach nasledujúcich v sekvencii za sebou.

5.1 PRAHOVÉ METÓDY

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

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 *príznamku* obrazu a podľa tejto hodnoty zatriedime obrazové body do oblastí.

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

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

- *Diskriminačná účinnosť* - príznaky pre rôzne objekty musia mať podstatne odlišné vlastnosti.
- *Spoločnosť* - príznaky pre tie isté objekty by mali mať tie isté alebo aspoň veľmi podobné vlastnosti.
- *Nezávislosť* - potrebná je vzájomná nekorelovanosť príznakov.
- *Malý počet* - zložitnosť celého systému je priamo úmerná počtu príznakov.

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 diskretných hodnôt početností jednotlivých úrovní jasu. 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 (Gonzalez, 1992). 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 $g(x, y)$ podľa vzťahu

$$g(n_1, n_2) = \begin{cases} u_0 & \text{pre } f(n_1, n_2) \leq t \\ u_{l-1} & \text{pre } f(n_1, n_2) > t \end{cases} \quad (5.1)$$

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 jasu v jednotlivých bodoch obrazu, hovoríme o *bodovo závislých metódach*. Ak je prah závislý aj od lokálnej vlastnosti (napr. rozloženie úrovni jasu) 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 zvlášť. Ak sa prahová hodnota jasu mení v závislosti na polohe bodu na obraze, metóda sa nazýva *dynamická*, príp. 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 jasu na obrazoch nemusí byť vždy také, že v histograme jasne vidieť dominantné módy. Často dochádza k ich prekryvaniu. Spôsobuje to premenlivosť úrovni jasu na povrchu objektov alebo pozadia. Môže byť zapríčinená napr. nerovnomernosťou osvetlenia, nehomogenitou oblasťou a pod. To má za následok porušenie modalít histogramu. Prejaví sa to tým, že

výrazné minimum medzi dominantnými módmí buď nie je možné jednoznačne určiť, alebo vôbec neexistuje.

Na ilustráciu uvedieme jednu globálnu prahovú metódu. Predpokladajme, že $f(n_1, n_2)$ je funkciou jasú obrazu zloženého z dvoch oblastí - objektu a pozadia (Gonzalez, 1992). Nech $h(u)$ je histogram tohoto obrazu. Ak rozmer obrazu je $N = n \times n$, potom pre funkciu $h(u)$ platí:

$$\sum_i h(u_i) = n^2 \text{ pre } i = (0, 1, \dots, I-1) \quad (5.2)$$

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

$$p(u_i) = \frac{h(u_i)}{n^2} \quad (5.3)$$

Platí

$$\sum_i p(u_i) = 1 \quad \text{kde } p(u_i) \geq 0 \quad i = (0, 1, \dots, I-1) \quad (5.4)$$

Hodnota $p(u_i)$ predstavuje pravdepodobnosť výskytu i -tej úrovne jasú na obraze. Funkciu $p(u)$ môžeme považovať za odhad funkcie hustoty pravdepodobnosti úrovni jasú. Takto môžeme označiť aj odhad funkcie hustoty úrovni jasú objektu a pozadia. Nech je teda $p_1(u)$ odhad funkcie hustoty pravdepodobnosti úrovni jasú 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 (5.4), musia byť funkcie $p_1(u)$ a $p_2(u)$ váhované, to znamená násobené koeficientami, ktoré môžeme chápať ako normovanú mieru veľkosti objektu a pozadia. Nech týmito koeficientami sú P_1 a P_2 pričom platí $P_1 + P_2 = 1$. Potom

$$p(u) = P_1 \cdot p_1(u) + P_2 \cdot p_2(u) \quad (5.5)$$

Ak za prahovú hodnotu zvolíme úroveň jasú t , ležiacu medzi dvoma maximami funkcie a zaradíme body obrazu do klasifikačných oblastí podľa predpisu pre binárne prahovanie, dopustíme sa takej chyby, že určitý počet bodov patriaci do objektu bude zaradený ako body pozadia a naopak, niektoré body obrazu patriace pozadiu budú klasifikované ako body objektu. Veľkosť tejto chyby môže nadobúdať rozličné hodnoty v závislosti na polohe prahu t , čo môžeme vyjadriť vzťahom:

$$\varepsilon(t) = P_1 \cdot \sum_{u=u_0}^t p_2(u) + P_2 \cdot \sum_{u=t+1}^{u_{I-1}} p_1(u) \quad (5.6)$$


Najlepšia hodnota prahu bude zrejme tá, pre ktorú funkcia (5.6) nadobúda minimum. Pre niektoré spojité funkcie, ako napríklad *Gaussovo (normálne) rozdelenie pravdepodobnosti* s parametrami μ_1 , σ_1 a μ_2 , σ_2 má chybová funkcia tvar

$$\varepsilon_S(t) = P_1 \cdot \int_{-\infty}^t p_2(u) \cdot du + P_2 \cdot \int_t^{\infty} p_1(u) \cdot du \quad (5.7)$$

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. 5.1).

Často nastáva prípad, keď sa módy histogramu natoľko prekrývajú, že nie je možné určiť minimum a parametre μ_1 , σ_1 , μ_2 , σ_2 , P_1 a P_2 nie sú známe. Môžeme spraviť odhad týchto parametrov. Jednou z možností je použitie metódy najmenších štvorcov (MSE) tak, aby sme dosiahli čo najmenší rozdiel medzi vypočítanou hodnotou funkcie $p(u)$ a jej odhadom.



Obr. 5.1 *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.*

5.2 METÓDY ZHLUKOVEJ ANALÝZY

S narastajúcou výkonnosťou výpočtovej techniky sa vytvárajú podmienky pre uplatnenie metód zhlukovej analýzy v oblasti segmentácie obrazu. Veľkou výhodou týchto metód je, že nevyžadujú žiadne znalosti o analyzovanom obraze a vychádzajú iba z existujúcich príznakov obrazu (napr. jasu). Sú to metódy, ktoré sa snažia o kvantifikáciu pojmov ako podobnosť, či homogenita (Halada, 1991). Ďalej sú uvedené dve skupiny týchto metód - *hierarchické a nehierarchické* - podľa postupu, akým získavame homogénne oblasti.

5.2.1 Metódy hierarchického štiepenia a spájania oblastí

Ako vyplýva z názvu, ide o rozdelenie originálneho obrazu na také časti, ktoré budú z hľadiska vopred stanoveného kritéria homogénne a maximálne. Oblasť je maximálna vtedy, keď pripojením ktorejkoľvek susednej oblasti by bola porušená jej homogenita. Výsledkom tohto postupu teda budú oblasti prvkov, ktoré si budú v nejakom zmysle podobné. Kritérium podobnosti, či homogenity a jeho voľba je jedným z najdôležitejších krokov celého postupu. Najjednoduchším klasifikačným kritériom môže byť blízkosť alebo rovnosť úrovni jasu v porovnávaných oblastiach, čo sa dá vyjadriť vzťahom

$$|\mu - u_i| \leq 2 \cdot \sigma \quad (5.8)$$

kde u_i je úroveň jasnosti obrazového bodu, μ predstavuje strednú hodnotu úrovni jasnosti v oblasti a σ je ich smerodajná odchýlka. Ak máme stanovené kritérium, máme k dispozícii tri možnosti na vytvorenie oblastí. Body obrazu môžeme

- postupne spájať do oblastí,
- postupne štiepiť obraz na menšie časti, alebo
- oba tieto postupy kombinovať.

V prvom prípade predstavuje na začiatku celého postupu každý bod obrazu samostatnú homogénnu oblasť. *Postupným porovnávaním a spájaním* vytvárame stále väčšie oblasti dovtedy, pokiaľ sú novo vznikajúce oblasti z hľadiska podmienky homogénne. Metódy využívajúce tento postup sa navzájom líšia počiatočným rozdelením obrazu a kritériom, na základe ktorého sa oblasti spájajú. Výsledok segmentácie je výrazne závislý od poradia, v ktorom sú jednotlivé podoblasti predkladané na porovnanie a spájanie. Môže vzniknúť situácia, že spojenie oblastí, ktoré bolo pri konkrétnom poradí realizované, bude zamietnuté, ak sa poradie spracovania oblastí zmení. Pokusy o spojenie s inými oblasťami sa ukončia až vtedy, keď danú oblasť nemožno spojiť so žiadnou susednou oblasťou. Takúto oblasť považujeme za výslednú.

Druhou možnosťou je opačný postup - *hierarchické štiepenie vstupného obrazu* na podoblasti. Ak oblasť nespĺňa podmienku homogenity, štiepi sa na podoblasti. Štiepenie pokračuje dovtedy, kým nie sú všetky podoblasti homogénne. Je zrejme, že obraz by sa dal takto štiepiť až na úroveň bodu. Z toho by sa mohlo zdať, že oba postupy sú duálne, a teda oboma postupmi musíme dôjsť k tomu istému výsledku. Každý postup však aj pri použití toho istého kritéria môže viesť k inému výsledku. Je to spôsobené tým, že pri štiepení na podoblasti sa určitá oblasť môže javiť ako homogénna, čo znamená, že ju ďalej nebudeme štiepiť, zatiaľ čo pri spájaní môže byť postupnosť vedúca k rovnakej oblasti odmietnutá.


Spojením štiepenia a spájania oblastí možno zachovať výhody oboch postupov. Ak je oblasť nehomogénna, rozštiepime ju napríklad na štyri podoblasti. Ak však nastane situácia, že štyri podoblasti toho istého typu (na tej istej úrovni) sú navzájom homogénne, spojíme ich do jednej oblasti (Gonzalez, 1992, Schalkoff, 1989, Šonka, 1992).

5.2.2 Nehierarchické metódy zhlukovej analýzy

Pre túto skupinu metód je charakteristické stanovenie, či odvodenie počtu zhlukov na začiatku algoritmu. Tie predstavujú počiatočný rozklad obrazu na disjunktné zhluky obrazových bodov. Tento rozklad v ďalšom postupe zlepšujeme dvoma spôsobmi. Buď zachováme počet zhlukov, alebo sa počet zhlukov mení v závislosti od riadiacich parametrov.

Pomerne jednoduché je stanoviť počiatočný rozklad, ak sú známe objekty, ktoré chceme segmentovať. Táto informácia vedie k určeniu typických objektov vyskytujúcich sa na obraze ako reprezentantov zhlukov. Výberom typického bodu získame miesto na obraze, okolo ktorého sa bude vytvárať budúci segment. Ak však nemáme počiatočnú informáciu o počte objektov na obraze, môžeme použiť iný spôsob segmentácie, ktorý umožňuje zároveň s klasifikáciou bodov modifikovať počas výpočtu počet zhlukov. Veličina, ktorá podlieha klasifikácii, je *vektor príznakov*. Ak poznáme vektory príznakov jednotlivých bodov obrazu, môžeme ich zaradiť do tried. Tie vektory, ktoré nemôžeme zaradiť do žiadnej z existujúcich tried, sa stanú zárodkami nových tried. Takto vytvorené triedy podrobíme analýze, pri ktorej skúmame možnosti spojenia existujúcich tried. Celý proces končí vtedy, keď už pri ďalšej analýze obrazu nedochádza k žiadnej zmene v klasifikácii bodov, či tried.

Tieto metódy vyžadujú interaktívny prístup. Vhodným stanovením riadiacich parametrov môžu byť dosiahnuté uspokojivé výsledky.



Obr. 5.2 Príklad segmentácie nehierarchickou metódou zhlukovej analýzy, a) originál, b) segmentovaný obraz.

5.3 METÓDY DETEKCIE HRÁN

Metódy patriace do tejto skupiny sú založené na vyhodnocovaní *rozdielu* v hodnotách úrovne jasú, ktoré možno pozorovať na obraze pri prechode z pozadia na objekt, alebo medzi dvoma rôznymi typmi objektov (Gonzalez, 1992). To znamená, že skúmaním množiny susedných bodov obrazu môžeme nájsť hrany a ich spojením získame hranice oblastí. Hrany medzi oblasťami predstavujú určitú nespojitosť, najčastejšie v hodnote jasú, farby alebo textúry.


Budeme sa zaoberať zmenami jasú. Ak si signál v riadku obrazu predstavíme ako funkciu $f(x)$, môžeme pomocou derivácie nájsť také body v riadku, v ktorých sa signál náhle mení. Prvá derivácia funkcie nadobúda nenulové hodnoty na miestach, kde signál mení svoju hodnotu. Na miestach, kde funkcia nemení svoju hodnotu, je prvá derivácia nulová. V bode x_0 dochádza k výraznej zmene hodnoty jasú. V tomto bode nadobúda prvá derivácia $f'(x)$ maximum. Druhá derivácia $f''(x)$ nadobúda nenulovú hodnotu tam, kde sa mení prvá derivácia. Prvá derivácia môže byť teda použitá na detekciu hrany v obraze a druhá derivácia je vhodná na určenie typu prechodu, to znamená, či sa jedná o prechod z tmavšej oblasti do svetlejšej alebo naopak. Oba tieto prípady sú znázornené na obr. 5.3.

Postup určenia hranových bodov je znázornený na obr. 5.4. Najprv vypočítame $|f'(x)|$ z funkcie $f(x)$. Následne tento výsledok porovnáme so zvolenou prahovou hodnotou. Len ak je hodnota $|f'(x)|$ väčšia než zvolená prahová hodnota, obrazový bod považujeme za súčasť hrany. Je obtiažne zvoliť optimálnu prahovú hodnotu. Zvyčajne nájdeme viacero bodov, ktoré spĺňajú stanovenú podmienku. Zvyšovaním prahovej hodnoty sa kandidátmi na hranu stávajú iba tie body, v ktorých sa $f(x)$ mení veľmi rýchlo. Ak bude prahová hodnota vysoká, dôjde k strate menej výrazných hrán. Jednou z možností je zvoliť prahovú hodnotu na základe metódy pokus – omyl, prípadne voliť prah adaptívne.


Analogicky možno *gradientom* vyšetriť priebeh dvojrozmernej funkcie $f(x, y)$. Gradient $\nabla f(x, y)$ funkcie $f(x, y)$ v bode (x, y) je vektor so zložkami $\partial f(x, y) / \partial x$ v smere osi x a $\partial f(x, y) / \partial y$ v smere osi y :

$$\nabla f(x, y) = \frac{\partial f(x, y)}{\partial x} \cdot i_x + \frac{\partial f(x, y)}{\partial y} \cdot i_y \quad (5.9)$$

kde x a y sú súradnice bodu, pre ktorý sa gradient vyšetruje a i_x a i_y sú jednotkové vektory v smere osí x a y . Nech $f(x, y)$ je funkcia úrovne jasu monochromatického obrazu. Postup detekcie hrán v dvojrozmernom signáli založený na predchádzajúcich úvahách je zobrazený na obr. 5.5.



Obr. 5.3 Priebehy a) $f(x)$, b) $f'(x)$, c) $f''(x)$ pre typickú jednorozmernú hranu.



Obr. 5.4 Systém jednorozmernej detekcie hrán.

Aplikovaním horeuvedených postupov často vzniknú hrubé pásy namiesto tenkých hraníc oblastí. Dodatočne môžeme sprísniť kritériá na výber hraničných bodov z nájdených kandidátov. Tento postup sa nazýva *zjemňovanie hrán* (*edge thinning*). Z kandidátov na hraničné body vyberieme napríklad iba tie, ktoré dosahujú lokálne maximum gradientu aspoň v jednom smere. Vo väčšine prípadov stačí kontrolovať maximum v horizontálnom a vo vertikálnom smere. Nevýhodou takéhoto jednoduchého algoritmu na výber hrán je vznik falošných (slabších) hrán v blízkosti pravých (silných) hrán. Jednou z možností, ako zabrániť vzniku falošných hrán, je použitie nasledujúcich kritérií:

- Ak má $|\nabla f(x, y)|$ lokálne maximum v bode (x_0, y_0) v horizontálnom, ale nie vo vertikálnom smere, potom je bod (x_0, y_0) hraničným bodom, ak:

$$\left| \frac{\partial f(x, y)}{\partial x} \right|_{x=x_0, y=y_0} > k \cdot \left| \frac{\partial f(x, y)}{\partial y} \right|_{x=x_0, y=y_0} \quad (5.10)$$


kde k je štandardne volené okolo 2.

- Ak má $|\nabla f(x, y)|$ lokálne maximum v bode (x_0, y_0) vo vertikálnom, ale nie v horizontálnom smere, potom je bod (x_0, y_0) hraničným bodom, ak platí:

$$\left| \frac{\partial f(x, y)}{\partial y} \right|_{x=x_0, y=y_0} > k \cdot \left| \frac{\partial f(x, y)}{\partial x} \right|_{x=x_0, y=y_0} \quad (5.11)$$

kde k volíme okolo 2.

Tieto vzťahy odrážajú skutočnosť, že zmena intenzity v jednom smere (horizontálnom alebo vertikálnom) musí byť omnoho väčšia než zmena v druhom smere.



Obr. 5.5 Dvojrozmerný systém pre detekciu hrán.

Systémy na detekciu hrán založené len na veľkosti gradientu $|\nabla f(x, y)|$ sa nazývajú *nesmerové detektory hrán*, pretože nie sú citlivejšie na jeden smer viac ako na druhý. Ak je systém založený na funkciách, ktoré sú citlivé na jeden smer viac ako na druhý, hovoríme o *smerovom detektore hrán*. Ak by sme v systéme na [obrázku 5.5](#) nahradili funkciu $|\nabla f(x, y)|$ funkciou $|\partial f(x, y) / \partial x|$, dostali by sme smerový systém, ktorý by detekoval hrany vo vertikálnom smere, ale nie v horizontálnom smere.

Pre spracovanie digitálneho signálu $f(n_1, n_2)$ použijeme pri výpočte gradientu namiesto derivácií *diferencie*. Je niekoľko možností výpočtu gradientu diskkrétnej funkcie. Napríklad $\partial f(x, y) / \partial x$ môžeme nahradit' nasledovne:

$$\frac{\partial f(x, y)}{\partial x} \leftrightarrow G_{n1} = \frac{f(n_1, n_2) - f(n_1 - 1, n_2)}{T} \quad (5.12a)$$

$$G_{n1} = \frac{f(n_1 + 1, n_2) - f(n_1, n_2)}{T} \quad (5.12b)$$


$$G_{n1} = \frac{f(n_1 + 1, n_2) - f(n_1 - 1, n_2)}{2 \cdot T} \quad (5.12c)$$

Výpočet gradientu z viacerých hodnôt dvojrozmernej funkcie je menej citlivý na prípadný šum. Príklad vylepšeného odhadu $\partial f(x, y) / \partial x$ môže vyzerat' nasledovne:

$$\begin{aligned} \frac{\partial f(x, y)}{\partial x} \leftrightarrow & [f(n_1 + 1, n_2 + 1) - f(n_1 - 1, n_2 + 1)] + [f(n_1 + 1, n_2) - f(n_1 - 1, n_2)] \\ & + [f(n_1 + 1, n_2 - 1) - f(n_1 - 1, n_2 - 1)] \end{aligned} \quad (5.12d)$$

$$\text{alebo } \begin{aligned} & [f(n_1 + 1, n_2 + 1) - f(n_1 - 1, n_2 + 1)] + 2 \cdot [f(n_1 + 1, n_2) - f(n_1 - 1, n_2)] \\ & + [f(n_1 + 1, n_2 - 1) - f(n_1 - 1, n_2 - 1)] \end{aligned} \quad (5.12e)$$

Na operácie vo vzťahoch (5.12a-e) sa môžeme pozeráť ako na konvolúciu funkcie $f(n_1, n_2)$ a impulzovej odpovede filtra $h(n_1, n_2)$. Príklady impulzovej odpovede $h(n_1, n_2)$, ktorú môžeme využiť na vytváranie detektorov hrán, sú zobrazené na [obrázku 5.6](#).



Obr. 5.6 Impulzové odpovede filtrov, ktoré môžu byť použité na detekciu hrán. a) Detektor pre vertikálne hrany, b) pre horizontálne hrany, c) a d) pre diagonálne hrany.

Nesmerový detektor hrán môžeme vytvoriť diskretnou aproximáciou absolútnej hodnoty gradientu $|\nabla f(x, y)|$ zo systému na [obrázku 5.5](#). Podľa (5.9)

$$|\nabla f(x, y)| = \sqrt{\left(\frac{\partial f(x, y)}{\partial x}\right)^2 + \left(\frac{\partial f(x, y)}{\partial y}\right)^2} \quad (5.13)$$


Príklad diskretnej aproximácie vzťahu (5.13), ktorá môže byť použitá pre nesmerové detektory hrán je:

$$|\nabla f(x, y)| \rightarrow \sqrt{(f_x(n_1, n_2))^2 + (f_y(n_1, n_2))^2} \quad (5.14)$$

$$\text{kde } f_x(n_1, n_2) = f(n_1, n_2) * h_x(n_1, n_2)$$

$$f_y(n_1, n_2) = f(n_1, n_2) * h_y(n_1, n_2)$$

pričom $h_x(n_1, n_2)$ a $h_y(n_1, n_2)$ sú na obr. 5.7.



Obr. 5.7 Aproximácia a) $\partial f(x, y) / \partial x$ pomocou $f(n_1, n_2) * h_x(n_1, n_2)$, b) $\partial f(x, y) / \partial y$ pomocou $f(n_1, n_2) * h_y(n_1, n_2)$. Sobelova metóda detekcie hrán je založená na porovnávaní gradientu so zvolenou prahovou hodnotou.

Zložky gradientu počítame najčastejšie v oblasti 3x3 obrazové body. Nech body obrazu v tejto oblasti nadobúdajú úroveň jasů u_i , $i = (1, 2, \dots, 9)$:

$$\begin{pmatrix} u_1 & u_2 & u_3 \\ u_4 & u_5 & u_6 \\ u_7 & u_8 & u_9 \end{pmatrix} \quad (5.15)$$

Gradient vypočítame aplikáciou masky. Môžeme použiť napríklad tzv. *Sobelove masky* (Gonzalez, 1992, Schalkoff, 1989, Šonka, 1992):

$$\text{v smere osi } x: \begin{pmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{pmatrix} \quad \text{v smere osi } y: \begin{pmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{pmatrix} \quad (5.16)$$

Potom pre zložky gradientu G_x a G_y v bode u_5 platí

$$\begin{aligned} G_x &= (u_3 + 2 \cdot u_6 + u_9) - (u_1 + 2 \cdot u_4 + u_7) \\ G_y &= (u_7 + 2 \cdot u_8 + u_9) - (u_1 + 2 \cdot u_2 + u_3) \end{aligned} \quad (5.17)$$

Spojením hranových bodov by sme mali dostať súvislú líniu zodpovedajúcu obrysom objektu. To je však ideálny prípad, ktorý sa v praxi nevyskytuje často. Príčinou môže byť šum, nerovnomerné osvetlenie, citlivosť masky na rôznu orientáciu hrán a pod.


Z uvedeného vyplýva, že výsledok metód detekcie hrán výrazne závisí od presnosti, s akou nájdeme hranové body. Presnosť je tým väčšia, čím je obraz kvalitnejší, to znamená menej zašumený, obsahuje minimum tieňov a falošných jasových hrán.




(a)



(b)



(c)



(d)

Obr. 5.8 *Mapy hrán získané pomocou smerových a nesmerových detektorov: a) originál 256x256 bodov, b) výsledok po aplikovaní Sobelovho detektora hrán, c) výsledok po aplikovaní detektora vertikálnych hrán, d) výsledok po aplikovaní detektora horizontálnych hrán.*

Metódy zhlukovej analýzy a metódy detekcie hrán riešia duálny problém. Každá oblasť je reprezentovaná vlastnou uzavretou hranou a každá uzavretá hranica popisuje oblasť. Rozdielna podstata oboch skupín však spôsobuje, že môžu poskytovať navzájom rozdielne výsledky. Výsledky oboch postupov je možné kombinovať, a tak získať všestrannejšiu informáciu. Jednoduchým príkladom je graf závislostí (Šonka, 1992), kde sú oblasti reprezentované uzlami a vetvy grafu predstavujú susedné závislosti získané detekciou hraníc týchto oblastí.

Obr. 5.8a zobrazuje originál obrazu veľkosti 256x256 bodov. **Obr.5.8b** zobrazuje použitie Sobelovho detektora hrán (impulzové odpovede podľa **obr. 5.7**). **Obr. 5.8c,d** zobrazujú použitie vertikálneho a horizontálneho detektora hrán (impulzové odpovede na **obr 5.6a,b**).

5.4 SEGMENTÁCIA POROVNÁVANÍM SO VZOROM

Ďalším možným prístupom k segmentácii je vyhľadávanie známych objektov na obraze pomocou porovnávania so vzorom (Šonka, 1992). Úloha môže byť všeobecnejšia - nájsť na obraze miesta, kde sa vyskytuje daný vzor, pričom vzor má charakter obrazu. Okrem hľadania objektov môžeme metódu porovnávania využiť na určenie relatívneho pohybu objektov na obrazoch snímaných v rôznych časových okamihoch - napr. pohyb automobilu po ceste, mrakov na oblohe a pod. Z jediného snímku sa vyčlenia hľadané objekty - vzory a pomocou vhodne organizovaného prehľadávania sa nájdu rovnaké objekty v iných obrazoch. Na nájdenie najlepšieho priradenia sa používa vhodné optimalizačné kritérium, ktoré závisí od vlastností hľadaných objektov a od vzťahov medzi nimi. Optimalizačným kritériom môže byť jednoduchá vzájomná korelácia aj komplikovaný postup porovnávania grafov vytvorených podľa vlastností hľadaných objektov.

Segmentácia je jednoduchá v prípade, keď môžeme očakávať na obraze presnú kópiu vzoru. V praktických prípadoch je zvyčajne časť obrazu nejako porušená - vplyvom šumu, geometrickým skreslením, a pod. Preto nemôžeme hľadať absolútny súhlas so vzorom, ale len maximum vhodného kritéria - miery súhlasu. Všeobecnou mierou súhlasu je *vzájomná korelácia*.

Označme jasovú funkciu spracovávaného obrazu $f(n_1, n_2)$ a hľadaného vzoru $f_v(n_1, n_2)$. N_v nech je množina všetkých obrazových bodov vzoru. Vhodnými mierami súhlasu obrazu a vzoru umiestneného v polohe (k, v) na obraze $f(n_1, n_2)$ sú metrické vzťahy

$$S_{v1}(k, v) = \frac{1}{\max_{(n1, n2) \in N_v} |f(n_1 + k, n_2 + v) - f_v(n_1, n_2)|} \quad (5.18a)$$

$$S_{v2}(k, v) = \frac{1}{\sum_{(n1, n2) \in N_v} |f(n_1 + k, n_2 + v) - f_v(n_1, n_2)|} \quad (5.18b)$$

$$S_{v3}(k, v) = \frac{1}{\sum_{(n1, n2) \in N_v} [f(n_1 + k, n_2 + v) - f_v(n_1, n_2)]^2} \quad (5.18c)$$

Metódou segmentácie porovnávaním sú v obraze lokalizované všetky miesta, kde sa nachádzajú kópie vzoru. Tieto kópie sa musia zhodovať so vzorom vo veľkosti aj v orientácii. Aby sme mohli použiť metódu porovnávania aj na hľadanie rôzne natočených a zväčšených vzorov, bolo by nutné vytvoriť pre každú možnú veľkosť a orientáciu samostatný vzor. Inou možnosťou je použitie jediného vzoru, ale porovnávanie obrazu so všetkými dovolenými geometrickými transformáciami vzoru. To je výhodné, ak je k dispozícii informácia o pravdepodobnom type skresľujúcej transformácie.

Majme prípad, keď je povolené neobmedzené množstvo transformácií vzoru na obraze. Predstavme si, že vzor je zložený z častí, ktoré sú navzájom prepojené. Aj keď nie je možné nájsť úplný súhlas, spravidla sa dá nájsť súhlas medzi viacerými časťami obrazu a jednotlivými časťami vzoru. Cieľom je nájsť vhodnú kombináciu čiastočných súhlasov, ktorých spôsob prepojenia sa čo najviac približuje k vzoru.

Segmentácia porovnávaním so vzorom je časovo náročná aj pre najjednoduchšie prípady, keď nedochádza ku geometrickým transformáciám. Dá sa však urýchliť vhodnou postupnosťou operácií hľadania a tiež využitím ďalších informácií o obraze.

5.5 METÓDY SEGMENTÁCIE TEXTÚROVÝCH OBRAZOV

Segmentácia textúr je dôležitou súčasťou procesov vedúcich k porozumeniu a popisu umelo vytvorených, ale aj reálnych obrazov (Schalkoff, 1989). Prvým krokom je nájdenie takých príznakov textúr, ktoré zabezpečia dostatočnú diskriminačnú účinnosť a zároveň sa dajú spočítať jednoduchým spôsobom. Aj keď nemáme presnú, všeobecne prijatú definíciu textúry, každý si vie textúru predstaviť. Textúra predstavuje viditeľné variácie úrovne jasu v nejakej oblasti. Napr. obraz púšte (piesku) má viditeľne inú textúru, ako obraz lesa. Navyše oblasti môžu obsahovať smerovo závislé textúry, ktoré ich odlišujú od ostatného okolia.

Metódy na segmentáciu textúr môžeme rozdeliť do dvoch skupín:

- *Štatistické metódy* využívajú príznaky textúr ako sú napr. stredná hodnota okolia bodov obrazu, disperzia, korelácia, entropia, kontrast, homogenita.
- *Štrukturálne metódy* sledujú napr. hrúbku vzoru, ktorý sa opakuje, orientáciu, tvar, polohu, a pod., to znamená model, podľa ktorého textúra vznikla, a ktorý umožňuje kvantitatívne vyhodnotenie príznaku textúry.

Metódy sú spravidla založené na výpočte štatistických veličín, ako sú stredná hodnota, disperzia, korelácia, a pod. Ďalšie možné kritériá sú energia, entropia, kontrast alebo homogenita jasu na obraze. Jednotlivé charakteristiky sa vypočítavajú zo stanoveného okolia obrazových bodov.

Vlastnosti textúry v určitom bode obrazu sú dané jeho vzťahom k susedným obrazovým bodom. Vo všeobecnosti, ak používame okná na odhad jednotlivých kritérií, je ťažké určiť optimálny rozmer okna. Voľba okolia sledovaného bodu (t.j. určenie veľkosti okna) je dôležitý krok v segmentácii textúr. Použitím okna s malými rozmermi môžeme odhadnúť štatistiky textúr lepšie na hraniciach, resp. vo vnútri malých oblastí, ale zvyšuje sa tým štatistická mnohotvárnosť (variabilnosť) v porovnaní so štatistikami získanými pomocou veľkého okna. To znamená, že drobné rozdiely v textúre veľkým oknom pravdepodobne nenájdeme. Prostredníctvom veľkého okna získame štatistiky, ktoré nebudú také rôznorodé, čo je výhoda vo vnútri veľkých oblastí. Na druhej strane sa zväčší nepresnosť štatistických charakteristík na hraniciach medzi oblasťami a vo vnútri malých oblastí. Možným riešením je použiť adaptívnu veľkosť okna.

5.6 METÓDY SEGMENTÁCIE POHYBLIVÉHO OBRAZU

Pri spracovaní statického obrazu môžeme potrebné informácie získať len zo vzájomných vzťahov medzi obrazovými bodmi. U pohyblivého obrazu môžeme navyše využiť zmenu obrazových bodov na snímkach idúcich za sebou. V sekvencii snímok môžeme túto medzislímkovú informáciu využiť na detekciu objektu, ktorý sa hýbe, zatiaľ čo pozadie je statické. Poloha bodov obrazu, ktoré sa na snímkach idúcich za sebou menia, určuje oblasť, kde sa pohybuje objekt. Pri použití algoritmu na detekciu rozhraní len v tejto oblasti dostaneme lepší výsledok, ako keď detekujeme hrany na celej snímke.

Obraz môžeme segmentovať na oblasti so zmenami a na oblasti bez zmien viacerými spôsobmi. Napríklad použitím tzv. Viterbi algoritmu (Lettera, 1989), keď snímku porovnávame s predchádzajúcou riadok po riadku a zaznamenávame len body, kde sme zistili rozdiel v úrovni jasu, t.j. kde nastal pohyb. Takýmto spôsobom klasifikujeme všetky body obrazu, teda určíme ich príslušnosť do jednej alebo druhej skupiny obrazových bodov (so zmenami a bez zmien).

Iná možnosť je odhad oblasti pohybu použitím algoritmu spájania a delenia oblastí. Ide o klasickú medzislímkovú segmentáciu, nie však bod po bode, ale po oblastiach. Pri delení obrazu na oblasti berieme do úvahy intenzitu jasu a polohu bodov na snímke. Algoritmus aplikujeme na dve snímky zo sekvencie. Po takejto prvotnej segmentácii oboch snímok porovnávame stredy oblastí, ktoré

si navzájom zodpovedajú. Na základe prahovej hodnoty rozhodujeme, či ide o oblasť zmeny, alebo o statické pozadie. Prahová hodnota v tomto prípade vyjadruje požadovanú presnosť lokalizácie oblasti pohybu. Je v nej zahrnutá poloha, úroveň jasů, tvar a priemerný rozdiel v úrovniach jasů medzi zodpovedajúcimi oblasťami na dvoch snímkach. V porovnaní s gradientnými metódami a metódou porovnávajúcou bloky konštantnej veľkosti dáva lepšie výsledky pre obrazy s výrazným pohybom a nie je citlivá na zmeny osvetlenia.

Ďalšiu možnosť segmentácie poskytuje algoritmus, ktorý využíva ako priestorovú, tak časovú koreláciu medzi snímkami a aplikuje metódu delenia oblastí. Je veľmi rýchly a odstraňuje chyby, ktoré vznikajú kódovaním veľkých blokov. Ide o adaptívne prispôsobovanie veľkosti bloku na základe lokálnych charakteristík obrazu, ako sú rozhrania v úrovni jasů, textúra (priestorová závislosť) a pohyb (časová závislosť).