KAPITOLA 10

VYUŽITIE SEGMENTÁCIE PRI KÓDOVANÍ OBRAZU

Kódovanie segmentovaných obrazov patrí k relatívne novým kompresným postupom [81]. Obraz najskôr rozdelíme na neprekrývajúce sa oblasti, v ktorých sa intenzita jasu mení len veľmi málo. Obrysy, ktoré oddeľujú jednotlivé oblasti, môžeme zakódovať napríklad niektorou z metód uvedených v kapitole 3, kým vnútro oblastí aproximujeme lineárnou kombináciou bázových funkcií.

Pri vysokých kompresných pomeroch poskytuje kódovanie segmentovaných obrazov výsledky s lepšou subjektívnou kvalitou než blokové transformačné kódovanie, ako napr. JPEG, pretože tu nevzniká rušivý blokový efekt.

10.1 SEGMENTÁCIA OBRAZU

Jednou z oblastí, kde sa využíva segmentácia, je analýza obrazu. Výsledkom analýzy je buď opis obrazu, alebo jeho zaradenie do určitej triedy, teda jeho klasifikácia na základe nejakej charakteristiky. Úlohou segmentácie 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 s určitými vlastnosťami, ktoré sú pre ne spoločné.

Za akých predpokladov môžeme dosiahnuť dobré výsledky segmentácie?

1. Oblasti segmentácie by mali byť homogénne vzhľadom na sledované charakteristiky - príznaky, ako napríklad úroveň jasu alebo textúra.
2. Vnútro oblastí by malo byť jednoduché, bez množstva "dier".
3. Susedné oblasti segmentácie by sa mali významne líšiť v hodnote sledovaného príznaku.
4. Hranice každého objektu by mali byť jednoduché, nie členité.

V praxi je splnenie týchto predpokladov ťažké, pretože jednotlivé oblasti majú často členité hranice a množstvo malých "dier". Predpoklad, že susedné oblasti majú veľké rozdiely v hodnote sledovanej charakteristiky môže viesť k splynutiu oblastí a strate hraníc. Metódy segmentácie obrazu majú rôznu presnosť, pretože zdôrazňujú jednu alebo viac želaných vlastností a robia kompromisy medzi viacerými požiadavkami.

Neexistuje všeobecne platná metóda vhodná pre segmentáciu každého obrazu. 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.

10.1.1 Segmentácia obrazu - definícia

Nech **x** je množina hodnôt obrazových bodov

$$\mathbf{x} = \{x(n_1,n_2),\ n_1 = 0,1,...,N_1\text{-}1,\ n_2 = 0,1,...,N_2\text{-}1\}, \tag{10.1}$$

kde x je úroveň jasu v bode obrazu so súradnicami (n_1,n_2),
$L = N_1 \times N_2$ je počet bodov obrazu. Cestou z bodu $({}^1n_1,{}^1n_2)$ do bodu $({}^2n_1,{}^2n_2)$ nazveme postupnosť obrazových bodov, ktoré sú susedné.

Nech $\mathbf{x}_1$ je neprázdna **súvislá podmnožina obrazových bodov** množiny **x**. Súvislosť množiny obrazových bodov znamená, že medzi každými dvoma bodmi existuje cesta, patriaca celá do množiny $\mathbf{x}_1$. Na základe zvoleného predpokladu P zaradíme jednotlivé obrazové body do podmnožín spojitých obrazových bodov $\mathbf{x}_k$.(Takýmto predpokladom môže byť napríklad určitá hodnota rozptylu úrovní jasu v segmentačnej oblasti obrazu.) Musí platiť, že ak množina $\mathbf{x}_1$ spĺňa zvolený predpoklad P, potom aj každá jej neprázdna podmnožina $\mathbf{x}_{11}$ spĺňa predpoklad P.

Segmentácia obrazu, ktorý má L bodov, pre ktoré platí predpoklad P, je rozklad množiny **x** na disjunktné podmnožiny $\mathbf{x}_1, \mathbf{x}_2,...\mathbf{x}_z$ také, že [83]:

1. $\cup \mathbf{x}_k = \mathbf{x}$	pre $k = 1, 2,... Z$	
2. $\mathbf{x}_k$ je súvislá množina obrazových bodov	pre $k = 1, 2,... Z$	
3. $P(\mathbf{x}_k) = 1$	pre $k = 1, 2,... Z$	(10.2)
4. $\mathbf{x}_k \cap \mathbf{x}_v = \varnothing$	pre $k \neq v$	

kde $\mathbf{x}_k$ a $\mathbf{x}_v$ sú **susedné**. Vzťah susednosti je v tejto definícii chápaný tak, že existuje aspoň jeden bod množiny $\mathbf{x}_k$, ktorý patrí do osemsusedstva niektorého bodu množiny $\mathbf{x}_v$.

Uvedené podmienky majú tento význam:

Prvá podmienka hovorí, že každý bod obrazu musí patriť do oblasti. To znamená, že segmentačný algoritmus by nemal skončiť skôr, než zaradí všetky body obrazu do oblastí.

Druhou podmienkou je, že každá oblasť musí byť súvislá.

Tretia podmienka predstavuje vlastnosť, ktorú majú mať oblasti získané segmentáciou, napríklad jednotná úroveň jasu, farba, textúra a pod.

Štvrtá podmienka je disjunktnosť oblastí segmentácie.

10.1.2 Požiadavky na segmentáciu pre kódovanie obrazu

Výsledky kódovania veľmi výrazne závisia od použitia vhodného segmentačného algoritmu. Na dosahovanie vysokých kompresných pomerov má zásadný vplyv počet oblastí, ktoré vytvoríme segmentáciou a počet obrazových bodov, ktoré tvoria hranice oblastí. Predovšetkým množstvo obrazových bodov, ktoré tvoria obrysy, rozhodujúcim spôsobom ovplyvňuje kompresný pomer, pretože najväčší počet bitov sa spotrebuje práve na zakódovanie hraníc segmentovaných oblastí. Z toho vyplýva, že minimalizácia počtu obrysových bodov je dôležitou požiadavkou pre vytvorenie účinného postupu kódovania segmentovaných obrazov.

Ak má byť segmentácia prínosom v oblasti kódovania, použitá metóda by mala spĺňať tieto požiadavky:

a) možnosť riadenia počtu oblastí a tým vlastne určovanie množstva detailov na segmentovanom obraze,

b) vytvorenie "hladkých" oblastí s pomaly sa meniacou intenzitou jasu, ktoré by sa dali aproximovať polynómami nízkych rádov,

c) vytvoriť pokiaľ možno čo najmenej malých oblastí, pretože kódovanie veľkého množstva malých oblastí spôsobuje znižovanie kompresného pomeru,

d)hranice oblastí nech sú čo najmenej členité, aby sa dali efektívne zakódovať.

10.2 METÓDY SEGMENTÁCIE OBRAZU

Metóda segmentácie, ktorú ďalej použijeme pre kódovanie obrazu, využíva kombináciu metódy zhlukovej analýzy a detekcie hrán. Preto sa najskôr budeme podrobnejšie zaoberať týmito segmentačnými postupmi.

10.2.1 Metódy zhlukovej analýzy

So zvyšujúcou sa výkonnosťou výpočtovej techniky sa vytvárajú podmienky pre uplatnenie výpočtovo náročných 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 [39], [82], [83], [84], [85].

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

1. Diskriminačná účinnosť - príznaky pre rôzne množiny musia mať podstatne odlišné vlastnosti.
2. Spoľahlivosť - príznaky pre tie isté objekty by mali mať tie isté, alebo aspoň veľmi podobné vlastnosti.
3. Nezávislosť - potrebná je vzájomná nekorelovanosť príznakov.
4. Malý počet - počet príznakov je priamo úmerný zložitosti celého systému.

Vo vytvorených oblastiach sa pôvodná hodnota videosignálu v jednotlivých bodoch nahradí zvoleným znakom príslušnosti k oblasti. Takýmto znakom môže byť napríklad určitá úroveň jasu.

Cieľom metód zhlukovej analýzy je kvantifikácia pojmov ako podobnosť, či homogenita. Dve skupiny týchto metód opíšeme podrobnejšie [84].

A. 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 jednak homogénne, jednak 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 úrovní jasu v porovnávaných oblastiach, čo sa dá vyjadriť vzťahom

$$|m - x_i| \le 2\sigma \,, \tag{10.3}$$

kde x_i je úroveň jasu obrazového bou m predstavuje strednú hodnotu úrovní jasu v oblasti a σ je smerodajná odchýlka.

Ak máme stanovené kritérium, máme k dispozícii tri možnosti na vytvorenie oblastí. Body obrazu môžeme

a) *postupne spájať do oblastí*,
b) *postupne štiepiť obraz na menšie časti* alebo
c) 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 novovznikajúce oblasti z hľadiska zvolenej podmienky homogénne. Metódy využívajúce tento postup sa navzájom líšia začiatočným rozdelením obrazu a kritériom, na základe ktorého sa oblasti spájajú. Výsledok segmentácie je výrazne závislý od poradia, v ktorom sú jednotlivé podoblasti predkladané na porovnávanie 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. To sa dá najlepšie ilustrovať na príklade štvorcového obrazu podľa obr. 10.1. Ak oblasť nespĺňa podmienku homogenity, štiepi sa na podoblasti. Štiepenie pokračuje dovtedy, kým nie sú všetky podoblasti homogénne. Táto metóda segmentácie sa často nazýva metódou kvadratného stromu (quadtree segmentation). Je zrejmé, že obraz by sa dal takto štiepiť až na úroveň bodu. Z toho by sa mohlo zdať, že oba postupy sú duálne, teda oboma postupmi musíme dôjsť k tomu istému výsledku. Každý postup však aj pri použití toho istého kritéria môže viesť k inému výsledku.

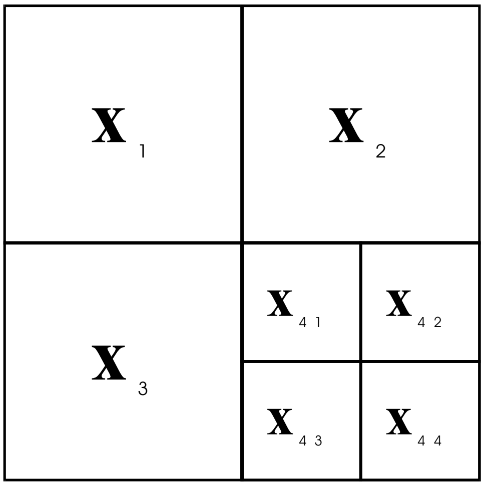

Obr. 10.1 Hierarchické štiepenie vstupného obrazu na homogénne oblasti

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 na štyri podoblasti. Ak však nastane situácia, že susedné podoblasti toho istého typu (na tej istej úrovni) sú navzájom homogénne, spojíme ich do jednej oblasti.

B. NEHIERARCHICKÉ METÓDY ZHLUKOVEJ ANALÝZY

Pre túto skupinu metód je charakteristické stanovenie, či odvodenie počtu zhlukov na začiatku algoritmu [84]. Tie predstavujú začiatočný rozklad obrazu na disjunktné zhluky obrazových bodov.

Tento rozklad v ďalšom postupe zlepšujeme dvomi spôsobmi. Buď zachováme počet zhlukov, alebo sa počet zhlukov mení v závislosti od riadiacich parametrov.

Pomerne jednoduché je stanoviť začiatočný rozklad, ak sú objekty, ktoré chceme segmentovať, známe. 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 začiatočnú 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. Ďalším krokom je výpočet aritmetických stredov týchto tried. Vektory príznakov, ktoré v predchádzajúcom kroku neboli zaradené, porovnávame so strednými hodnotami jednotlivých tried a zaradíme ich do tej triedy, ku ktorej sú najbližšie. Ak je však vzdialenosť od jednotlivých stredov tried väčšia ako zadaná prahová hodnota, klasifikovaný bod nezaradíme do žiadnej triedy. To znamená, že sa stane zárodkom novej triedy.

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, alebo tried.

10.2.2 Metódy detekcie hrán

Tieto metódy tvoria ďalšiu skupinu metód segmentácie [37], [82], [83], [85]. Sú založené na vyhodnocovaní *rozdielu* v hodnotách úrovne jasu, ktoré možno pozorovať na obraze pri prechode z pozadia na objekt, alebo medzi dvoma rôznymi typmi objektov. To znamená, že skúmaním množiny susedných bodov obrazu môžeme nájsť hrany a ich spojením získame hranice oblastí. Hrany medzi oblasťami predstavujú určitý skok, najčastejšie v hodnote jasu. Ak si signál v riadku obrazu predstavíme ako funkciu, môžeme pomocou derivácie nájsť také body v riadku, v ktorých sa hodnota signálu náhle mení.

Majme dva obrazy rôzneho charakteru [36], ako na obr. 10.2. (a), (b). Funkcie obrazu $x_1({}^0n_1,n_2)$ a $x_2({}^0n_1,n_2)$ vyjadrujú zmeny obrazovej funkcie v riadku ${}^0n_1$. Potom prvá derivácia takýchto funkcií nadobúda nenulové hodnoty v miestach, kde signál mení svoju hodnotu. V miestach, kde funkcie $x_1({}^0n_1,n_2)$ a $x_2({}^0n_1,n_2)$ nemenia svoju hodnotu, je ich prvá derivácia nulová.

Druhá derivácia nadobúda nulovú hodnotu všade okrem tých bodov, v ktorých 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 ide o prechod zo svetlej oblasti do tmavej, alebo naopak.

Určiť priebeh funkcie dvoch premenných $x(n_1, n_2)$ nám umožní *gradient* **G**. Z vektorovej analýzy vieme, že gradient je vektor orientovaný v smere maximálnej zmeny funkcie x v bode (n_1, n_2). Z hľadiska detekcie hrán nás zaujíma predovšetkým veľkosť vektora **G**

$$|\mathbf{G}[x(n_1,n_2)]| = \left[G_{n1}^2 + G_{n2}^2\right]^{1/2} . \tag{10.4}$$

Táto hodnota sa rovná maximálnej zmene amplitúdy funkcie $x(n_1,n_2)$ na jednotkovú vzdialenosť v smere vektora **G**. Smer gradientu môžeme vyjadriť ako uhol α, ktorý zviera vektor **G** s osou n_1

$$\alpha[\mathbf{G}[x(n_1,n_2)]] = arctg(G_{n2}/G_{n1}). \tag{10.5}$$

Táto veličina je zaujímavá pre spájanie hranových bodov a vytváranie súvislých hraníc oblastí. Sledovaním uhlu gradientu môžeme nájsť súvislé hranice oblastí na obraze [39],[82],[85].

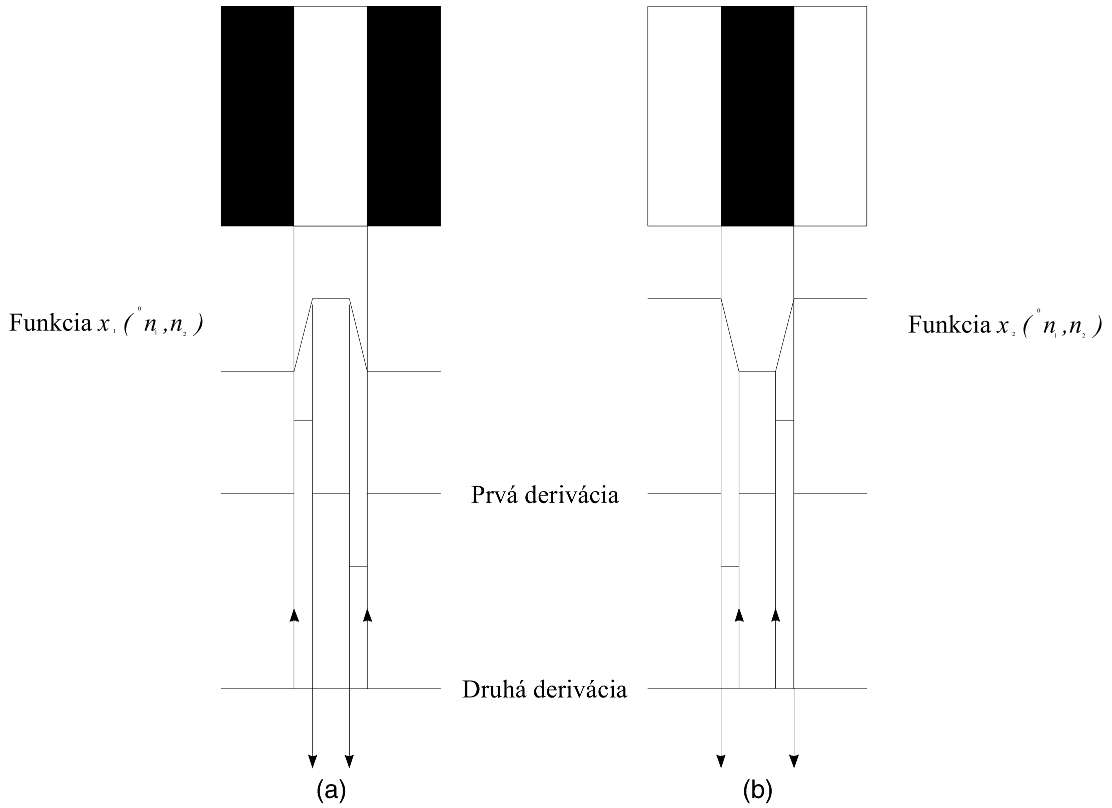

Obr. 10.2 Zmeny úrovne jasu v obrazoch a ich derivácie (a) svetlý objekt na tmavom pozadí (b) tmavý objekt na svetlom pozadí

Gradient $\mathbf{G}(n_1,n_2)$ funkcie $x(n_1,n_2)$ v bode (n_1,n_2) je dvojzložkový vektor so zložkami G_{n1} v smere osi n_1 a G_{n2} v smere osi n_2
.

$$\mathbf{G}[x(n_1,n_2)] = \begin{bmatrix} G_{n1} \\ G_{n2} \end{bmatrix} = \begin{bmatrix} \frac{\partial x}{\partial n1} \\ \frac{\partial x}{\partial n2} \end{bmatrix}. \tag{10.6}$$

Pre spracovanie digitálneho signálu použijeme pri výpočte gradientu namiesto derivácií *diferencie*. Je niekoľko možností výpočtu gradientu diskrétnej funkcie.

Môžeme použiť diferencie prvého rádu v oblasti 2 x 2 obrazové body:

.

$$\begin{bmatrix} x(n_1,n_2) & x(n_1,n_2+1) \\ x(n_1+1,n_2) & x(n_1+1,n_2+1) \end{bmatrix}. \tag{10.7}$$

Potom určíme veľkosť gradientu

$$|\mathbf{G}[x(n_1,n_2)]| \approx |x(n_1,n_2) - x(n_1+1,n_2)| + |x(n_1,n_2) - x(n_1,n_2+1)| \tag{10.8}$$

Takýto výpočet veľkosti gradientu sa však používa veľmi zriedka, pretože výsledok je veľmi citlivý na šum. Navyše, takto získaná charakteristika nie je symetrická.

O niečo zložitejšia je aproximácia zložiek gradientu vypočítaných v oblasti 3 x 3 obrazové body. Na druhej strane, keď počítame gradient z väčšieho okolia obrazového bodu, výsledok je menej citlivý na šum. Nech obrazové body v tejto oblasti nadobúdajú úroveň jasu x_i , i = (1,2 ,... 9)

$$\begin{bmatrix} x_1 & x_2 & x_3 \\ x_4 & x_5 & x_6 \\ x_7 & x_8 & x_9 \end{bmatrix}. \tag{10.9}$$

Veľkosť gradientu vypočítame aplikáciou masky **w**, ktorá obsahuje váhové koeficienty w_i

$$\mathbf{w} = \begin{bmatrix} w_1 & w_2 & w_3 \\ w_4 & w_5 & w_6 \\ w_7 & w_8 & w_9 \end{bmatrix}. \tag{10.10}$$

Algoritmus spočíva v konvolúcii masky s obrazom. Môžeme použiť napríklad *Sobelove operátory* [82], [85] pre výpočet zložky $G_{\mathrm{n}1}$

$$\mathbf{w}_{n1} = \begin{bmatrix} -1 & -2 & -1 \\ 0 & 0 & 0 \\ 1 & 2 & 1 \end{bmatrix} \tag{10.11}$$

a pre výpočet zložky $G_{\mathrm{n}2}$

$$\mathbf{w}_{n2} = \begin{bmatrix} -1 & 0 & 1 \\ -2 & 0 & 2 \\ -1 & 0 & 1 \end{bmatrix}. \tag{10.12}$$

Potom pre zložky vektora gradientu $G_{\mathrm{n}1}$ a $G_{\mathrm{n}2}$ v bode obrazu s intenzitou jasu x_5 platí

$$\begin{aligned} G_{n1} &= (x_7 + 2 \cdot x_8 + x_9) - (x_1 + 2 \cdot x_2 + x_3)\,, \\ G_{n2} &= (x_3 + 2 \cdot x_6 + x_9) - (x_1 + 2 \cdot x_4 + x_7). \end{aligned} \tag{10.13}$$

Kombináciou oboch zložiek v zodpovedajúcich obrazových bodoch dostaneme obraz, ktorý bude obsahovať veľkosť gradientu v každom bode obrazu normovanú na daný rozsah úrovní jasu. Hodnota gradientu bude tým väčšia, čím prudšia je zmena jasu v okolí bodu, pre ktorý ju počítame. Takto vytvorený obraz nazývame *gradientný obraz* (obr. 10.3 (b)) [36]

$$y(n_1, n_2) = |\mathbf{G}[x(n_1, n_2)]|. \tag{10.14}$$

V oblastiach, kde má originálny obraz $x(n_1,n_2)$ konštantnú, prípadne len málo sa meniacu intenzitu jasu, bude gradientný obraz tmavý, pretože gradient bude nadobúdať nulovú alebo veľmi malú hodnotu. Naopak, svetlé miesta na gradientnom obraze budú korešpondovať s oblasťami originálneho obrazu, v ktorých dochádza k veľkým zmenám intenzity jasu, a teda gradient nadobúda veľké hodnoty.

Predpokladajme, že nás zaujíma len poloha obrazových bodov s veľkou hodnotou gradientu, t.j. poloha obrazových bodov na rozhraní medzi oblasťami s výrazne odlišnou intenzitou jasu. Zvolíme si prahovú hodnotu P. Body obrazu, v ktorých je hodnota gradientu väčšia než prahová, považujeme za hranové body a priradíme im vhodnú úroveň jasu. Hodnotu videosignálu v ostatných obrazových bodoch nahradíme inou, dostatočne odlišnou hodnotou

$$y(n_1, n_2) = \begin{matrix} x_G & \text{ak } |\mathbf{G}[x(n_1, n_2)]| \geq P \\ x_B & \text{ak } |\mathbf{G}[x(n_1, n_2)]| < P \end{matrix}\,, \tag{10.15}$$

kde x_G a $x_{\boldsymbol{B}}$ sú dostatočne odlišné hodnoty úrovne jasu.

Pri detekcii hrán je veľmi dôležité určenie správnej prahovej hodnoty, t.j. rozhodovacej úrovne, kedy už hodnotu gradientu budeme považovať za dostatočne veľkú, aby zodpovedala významnej hrane medzi oblasťami a kedy ešte nie. Pri stanovení veľmi vysokej hodnoty rozhodovacej úrovne vznikajú nespojitosti (niektoré body rozhrania vôbec nenájdeme) a vtedy hovoríme o podsegmentovanom obraze. Naopak, stanovenie nízkej prahovej hodnoty spôsobí, že zaznamenáme aj veľmi malé zmeny úrovne jasu. Potom výsledný obraz bude obsahovať viac šumu, najmä v závislosti od kvality obrazového signálu. 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 a pod.

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

Metódy zhlukovej analýzy a metódy detekcie hrán riešia duálny problém. Každá oblasť je reprezentovaná vlastnou uzavretou hranicou a každá uzavretá hranica opisuje oblasť. Rozdielna podstata obidvoch skupín však spôsobuje, že môžeme očakávať rozdielne informácie o obraze. Výsledky oboch postupov je možné kombinovať, a tak získať všestrannejšiu informáciu.

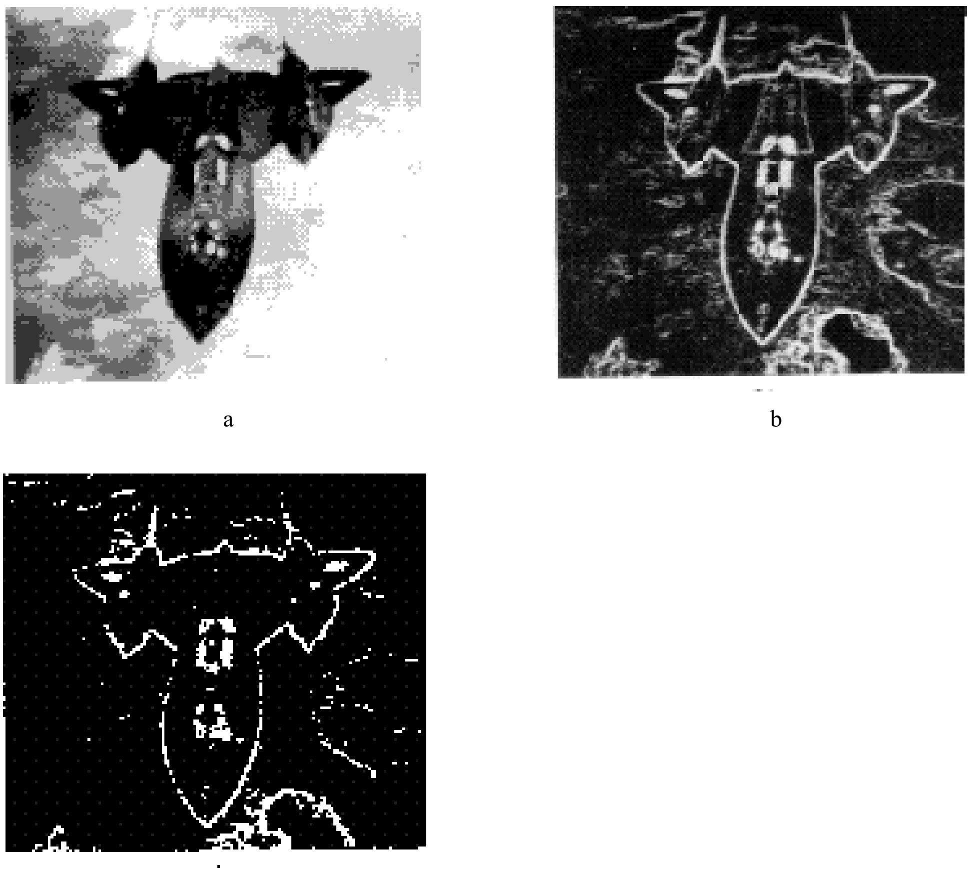

a b

c

Obr. 10.3 Detekcia hrán pomocou Sobelovych operátorov: originál (a), gradientný obraz (b), dvojúrovňový obraz hrán pre prahovú úroveň jasu P (c)

10.3 SEGMENTAČNÝ ALGORITMUS PRE KÓDOVANIE OBRAZU

V kódovaní obrazu majú veľký význam hranice homogénnych oblastí. Sú nositeľmi dôležitej informácie, bez ktorej nie je možná kvalitná rekonštrukcia obrazu. Opíšeme jednu z možností využitia segmentácie pre kódovanie obrazu [81].

V snahe minimalizovať riziko straty dôležitých informácií o hraniciach oblastí začína segmentačný algoritmus vytvorením ***nadsegmentovaného obrazu***. To znamená, že v prvom kroku rozdelíme obraz na veľké množstvo oblastí, z ktorých mnohé nebudú mať podstatný význam pre ďalšie spracovanie. Na druhej strane takto zabezpečíme uchovanie aj menej výrazných hraníc medzi segmentačnými oblasťami. Rozdelenie urobíme metódou zhlukovej analýzy, kombináciou štiepenia a spájania oblastí. Môžeme pri tom využiť modifikovaný postup, kde nebudeme obraz štiepiť na podoblasti v tvare tzv. kvadrátneho stromu (quadtree), ale použijeme na delenie informáciu o hraniciach získanú z gradientného obrazu. Touto modifikáciou získame oveľa prirodzenejšie hranice oblastí, a nie segmenty s pravouhlými hranami, ako v štandardnom postupe. Intenzitu jasu vo vnútri jednotlivých oblastí nahradíme strednou hodnotou úrovní jasu každej z nich.

Po ukončení štiepenia obrazu máme na ďalšie spracovanie veľké množstvo malých oblastí, mikrosegmentov. Každý mikrosegment je opísaný charakteristikami. Mnohé z mikrosegmentov sú často veľmi malé na to, aby boli pre ďalšie spracovanie významné.

V nasledujúcom kroku pospájame tie susedné mikrosegmenty, ktoré môžeme na základe ich charakteristík klasifikovať ako časti tej istej oblasti. Takouto charakteristikou môže byť napríklad stredná hodnota úrovní jasu mikrosegmentu. Ako kritérium pre spájanie susedných mikrosegmentov môžeme použiť rozdiel stredných hodnôt v susedných oblastiach, ktoré sú kandidátmi na spojenie. Toto kritérium však nie je veľmi výstižné a môže viesť ku vzniku veľkých oblastí. Veľké oblasti sú výhodné z hľadiska kódovania, ale dochádza k strate veľkého množstva informácií o hraniciach. Naším cieľom je dosiahnuť vysoký stupeň kompresie, ale obrysy sú pre rekonštrukciu dôležité a musia zostať zachované. Uvedieme iné kritérium pre spájanie mikrosegmentov. V procese spájania opäť využijeme gradientný obraz, ktorý sme si vytvorili vo fáze štiepenia. Ako kritérium budeme vyhodnocovať funkciu

$$CF(i,j) = \frac{grad(i,j)}{dsh(i,j)} \cdot \frac{velkost(i) \cdot velkost(j)}{dsh(i,j)} \cdot \left| m_i - m_j \right|, \tag{10.16}$$

kde

$dsh(i,j)$ je dĺžka spoločnej hranice medzi oblasťami i a j,

veľkosť(i),*veľkosť*(j) sú počty obrazových bodov patriacich do oblasti i,resp. j,

$grad(i,j)$ je súčet veľkostí gradientov pozdĺž spoločnej hranice oblastí i a j,

m_i a m_j sú stredné hodnoty intenzity jasu v oblastiach i a j.

Funkciu $CF(i,j)$ vypočítame pre všetky oblasti, ktoré vznikli štiepením. Na základe funkčnej hodnoty rozhodneme o spojení oblastí j a i. Najskôr spojíme oblasti s najmenšou funkčnou hodnotou. Po spojení vypočítame charakteristiky novovzniknutých oblastí a z nich následne nové funkčné hodnoty funkcie $CF(i,j)$. Postup opakujeme, kým nezískame požadovaný počet oblastí. Použitá funkcia uprednostňuje z hľadiska spájania oblasti s veľkou dĺžkou spoločnej hranice, s malým rozsahom (nízkym počtom obrazových bodov patriacich do oblasti) a malými rozdielmi v hodnotách intenzity (t.j. malými hodnotami gradientu na spoločnej hranici). Vypočítame gradient pozdĺž spoločnej hranice dvoch susedných oblastí. Pomer veľkostí gradientov pozdĺž spoločnej hranice oblastí i a j k jej dĺžke

$$grad(i,j)/dsh(i,j) \tag{10.17}$$

môžeme interpretovať ako mieru výraznosti hranice.

Člen

$$dsh(i,j) \tag{10.18}$$

zabezpečuje pripojenie tých malých oblastí, ktoré majú dlhšiu spoločnú hranicu so susednou oblasťou. Z posledného činiteľa funkcie je zrejmé, že dôjde k spojeniu oblastí s malým rozdielom stredných hodnôt intenzity jasu. Z hľadiska subjektívnej kvality obrazu umožňuje kritérium *CF(i,j)* získanie oveľa lepšej reprezentácie obrazu, než kritérium založené výlučne na vyhodnocovaní rozdielu stredných hodnôt intenzity jasu v susedných oblastiach.

Výsledky uvedenej metódy dokumentujú obr. 10.4 (a), (b), (c), (d). Originál je na obr. 10.4 (a). Na obr. 10.4 (b) je nadsegmentovaný obraz (asi 1300 oblastí), obr. 10.4 (c) obsahuje výsledok spájania na základe funkcie *CF*(*i,j*) a na obr. 10.4 (d) je rekonštruovaný obraz (kompresia je asi 39:1 pri použití 8 bitov na uchovanie strednej hodnoty intenzity jasu v danej oblasti). Výsledný počet oblastí je 200 a počet obrazových bodov, ktoré tvoria hranice, je 7429.

Uvedená segmentačná metóda využíva kombináciu zhlukovej analýzy a detekcie hrán. Tak v procese štiepenia ako aj spájania oblastí využíva informácie získané detekciou hrán, vďaka čomu spĺňa podmienky segmentácie pre kódovanie (a), (b), (c) a čiastočne splnené (d).

10.4 KÓDOVANIE VNÚTRA SEGMENTOV

Najnovšie metódy kódovania segmentovaných obrazov používajú na aproximáciu vnútra oblastí bázy ortonormálnych funkcií. Konštrukcia bázových funkcií v jednotlivých oblastiach segmentovaného obrazu je výpočtovo veľmi náročná, pretože ortogonálna báza pre danú oblasť závisí od tvaru aj od veľkosti oblasti. Z toho jasne vyplýva, že pre každú oblasť treba skonštruovať novú bázu.
Funkciu intenzity jasu $x(n_1,n_2)$ aproximujeme vo vnútri jednotlivých segmentov sumou váhovaných ortogonálnych bázových funkcií

$$u(n_1,n_2,k_1,k_2) : x(n_1,n_2) \approx \hat{x}(n_1,n_2) = \sum_{(k_1,k_2)\in\Im} a(k_1,k_2)\cdot U(n_1,n_2,k_1,k_2), \tag{10.19}$$

kde $\Im$ je množina vhodne zvolených indexov a $a(k_1, k_2)$ sú váhové koeficienty

$$a(k_1,k_2) = \sum_{n_1}\sum_{n_2} \hat{x}(k_1,k_2)\cdot U^{*T}(n_1,n_2,k_1,k_2) \tag{10.20}$$

ktoré predstavujú chybu aproximácie funkcie x funkciou $\hat{x}$ metódou najmenších štvorcov (4.4).

Výpočtová náročnosť metód na aproximáciu intenzity jasu vo vnútri oblastí je veľmi veľká. Závisí aj od zvolenej bázy ortogonálnych funkcií. Všeobecný princíp aproximácie je taký, že na aproximáciu jasu vo väčších oblastiach použijeme viac bázových funkcií, ako na aproximáciu jasu v malých oblastiach, aby sme ich mohli rekonštruovať s porovnateľnou kvalitou.

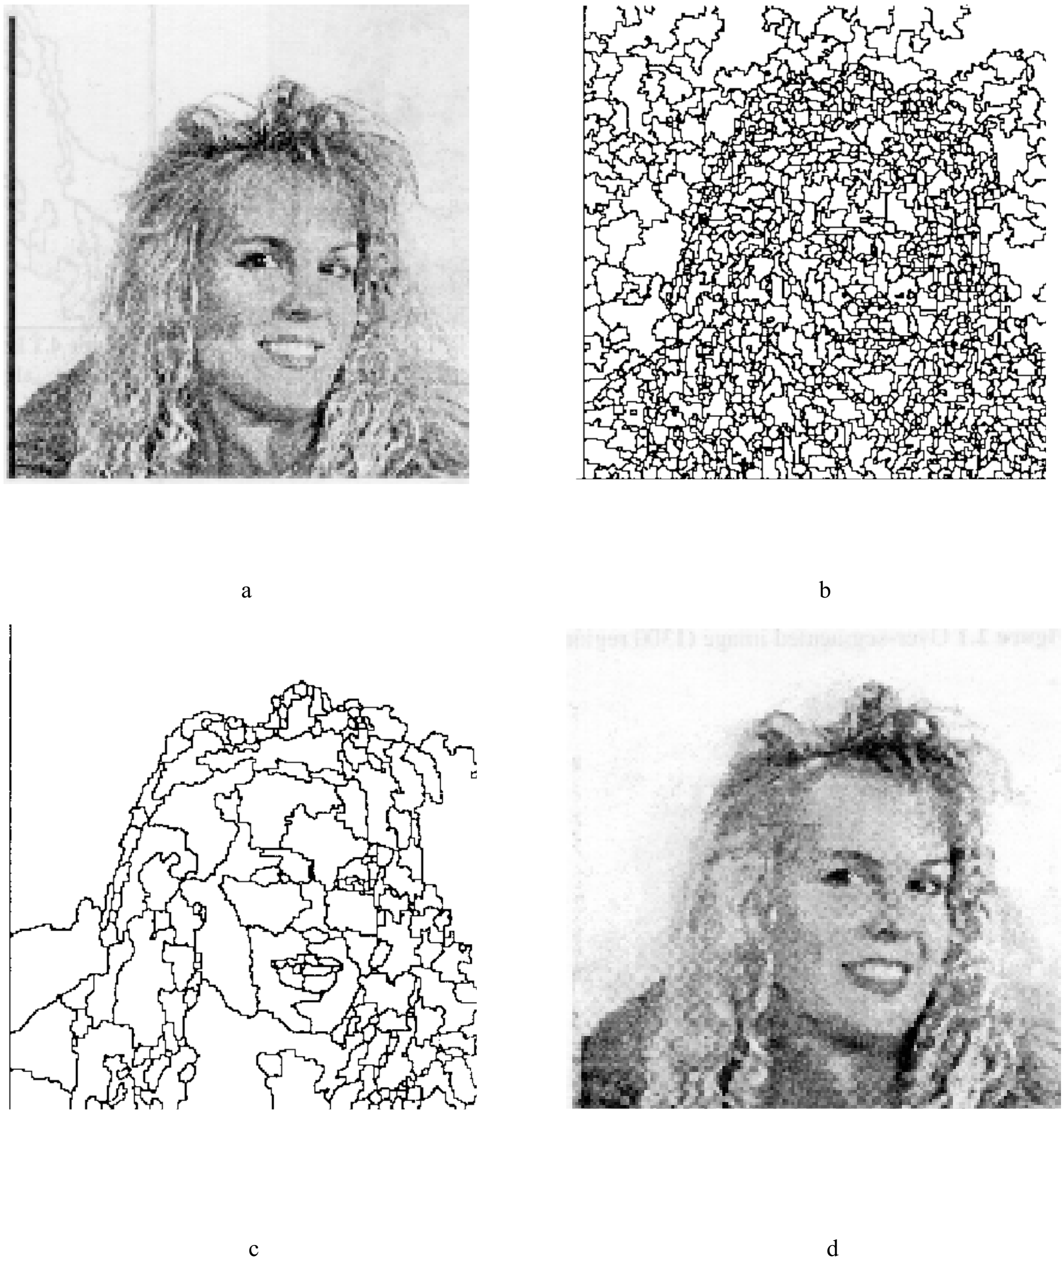

Obr. 10.4 Kódovanie segmentovaného obrazu: originál (a), nadsegmentovaný obraz (1300 oblastí) (b), výsledok spájania oblastí na základe funkcie $CF(i,j)$ (c), rekonštruovaný obraz (d)