

6.4 Metódy zhlukovej analýzy

Výkonnosť výpočtovej techniky v súčasnosti vytvára podmienky na 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. jas). Sú to metódy, ktoré sa snažia o kvantifikáciu pojmov ako podobnosť či homogenita. Ďalej sú uvedené dve skupiny týchto metód - *hierarchické* a *nehierarchické* - podľa postupu, akým získavame homogénne oblasti.

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 jasů v porovnávaných oblastiach, čo sa dá vyjadriť napríklad vzťahom

$$|\mu - u_i| \leq 2 \cdot \sigma \quad (6.24)$$

kde u_i je úroveň jasů obrazového bodu, μ predstavuje strednú hodnotu úrovni jasů 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, kým sú novo – vznikajúce oblasti z hľadiska podmienky (klasifikačného kritéria) homogénne. Metódy využívajúce tento postup sa navzájom líšia počiatčným 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.

Ako príklad uvedieme metódu narastania oblastí autorov S.A.Hojjatoleslami a J. Kittlera [HoKi98]. Metóda používa ako kritérium na nájdenie hraníc oblastí na obraze **priemerný kontrast $c(i)$** . Je vyjadrený ako rozdiel medzi priemerným jasom oblasti a priemerným jasom jej vonkajšej hranice. Vonkajšiu hranicu tvorí spojitý uzavretý reťazec obrazových bodov, ktoré hraničia s oblasťou, ale nepatria do nej. Tento kontrast narastá, kým je narastajúca oblasť homogénna. Ak pripojíme k oblasti body s rozdielnou úrovňou jasu, kontrast sa zmenší. Maximum kriteriálnej funkcie priemerného kontrastu teda určuje hranice homogénnej oblasti.

Kriteriálna funkcia $c(i)$ má tvar:

$$c(i) = \frac{1}{i} \cdot \sum_{k=1}^i X_k - \frac{1}{n-i} \cdot \sum_{k=i+1}^n X_k \quad (6.25)$$

kde X_1, X_2, \dots, X_i je množina bodov vytvorenej oblasti a

X_{i+1}, \dots, X_n je množina bodov vonkajšej hranice oblasti.

Maximum $c(i)$ v procese narastania oblasti teda korešponduje so stavom, keď oblasť začína prerastať do pozadia, resp. do inej oblasti. Výsledkom segmentácie je vonkajšia hranica oblasti (ACB-Average Contrast Boundary).

Metóda zahŕňa jedno prídavné kritérium: **okrajový kontrast**. Je definovaný ako rozdiel medzi priemernou úrovňou jasu bodov tvoriacich vonkajšiu hranicu oblasti (ACB) a priemernou úrovňou jasu bodov tvoriacich vnútornú hranicu oblasti (CB-Current Boundary). Okrajový kontrast vyjadruje priemernú veľkosť gradientu obrazových bodov vnútornej hranice oblasti (CB).


Vyhodnocovanie veľkosti gradientu medzi susednými hranicami je menej citlivé na šum, než vyhodnocovanie veľkosti gradientu medzi susednými bodmi.

Na stanovenie hodnoty zastavenia N je použitá hodnota priemerného kontrastu AC. Program pri narastaní oblasti zisťuje hodnotu AC a zapisuje jej postupnosť do súboru po každom pripojení obrazového bodu.

0	0	0	0	0	0	0	0	0	0
0	0	0	1	1	1	1	1	0	0
0	0	0	1	2	2	2	1	0	0
0	0	0	1	2	2	2	1	0	0
0	0	0	1	2	2	1	1	0	0
0	1	1	1	2	2	2	1	0	0
0	1	2	2	2	2	1	1	0	0
0	1	2	2	1	1	1	0	0	0
0	1	1	1	1	0	0	0	0	0
0	0	0	0	0	0	0	0	0	0


Obr.6.7. Príklad segmentu po použití kritéria **priemerný kontrast $c(i)$** . Číslom 2 sú mapované body patriace do oblasti, číslom 1 spojitá hranice tejto oblasti a zatiaľ nespracovávané body majú hodnotu 0

Druhou možnosťou delenia obrazu je opačný postup - **hierarchické štiepenie** vstupného obrazu na podoblasti. To sa dá najlepšie ilustrovať na príklade štvorcového obrazu podľa obr. 6.8. Ak oblasť nespĺňa podmienku homogenity, štiepi sa na podoblasti. Štiepenie pokračuje dovtedy, kým nie sú všetky podoblasti homogénne. Je zrejmé, 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.



Obr. 6.8. Hierarchické štiepenie obrazu na homogénne oblasti

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 [GoW92, Prat01, Scha89].



a) Originál

b) delenie

*c) spájanie
(počiatočná obl.:sveter)*

Obr. 6.9. Príklad segmentácie kombináciou štiepenia a spájania oblastí

Nehierarchické metódy zhlukovej analýzy

Charakteristickým znakom tejto skupiny metód je stanovenie či odvodenie počtu zhlukov na začiatku algoritmu. Tieto zhluky predstavujú počiatočný rozklad obrazu na disjunktné oblasti obrazových bodov. Počiatočný 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.

Mean shift algoritmus

je neparametrický iteračný algoritmus. Môže byť použitý napríklad na hľadanie módov, príp. vytváranie zhlukov v množine dát.

Intuitívna myšlienka Mean shift algoritmu

Množinu dát (príp. príznakov dát) považujeme za empirický odhad funkcie hustoty pravdepodobnosti. Množina bodov na vstupe je považovaná za vzorky predpokladanej funkcie hustoty pravdepodobnosti. „Hustejšie“ miesta (zhluky – clusters) v rozložení dát (príznakov dát) zodpovedajú módom (alebo lokálnym maximám) funkcie hustoty pravdepodobnosti. Môžeme teda identifikovať zhluky zodpovedajúce jednotlivým módom použitím Mean shift algoritmu.

Každý prvok množiny je priradený k najbližšiemu maximu (peak) funkcie hustoty pravdepodobnosti spracovávanej množiny. Pre každý prvok množiny algoritmus zdefinuje okno (okolie prvku) a vypočíta sa stredná hodnota. Potom sa posunie stred okna do vypočítanej strednej hodnoty a opakuje algoritmus, až kým algoritmus neskonverguje.

Po každej iterácii môžeme zistiť, že stredná hodnota (stred zhuku) sa posúva do „hustejšej“ oblasti množiny dát.

Stručný postup Mean shift algoritmu:

1. Zdefinuj okno okolo každého bodu v množine.
2. Vypočítaj strednú hodnotu (priemer) vo vnútri okna.
3. Posuň okno do vypočítaného stredu a opakuj, kým algoritmus neskonverguje.

Tento klasický Mean shift je výpočtovo náročný. Existuje veľa modifikácií, jednou z nich je

Adaptívny Mean shift algoritmus

Používa premenlivú veľkosť okna pre každý bod množiny. Algoritmus nemusí byť vhodný pre mnoho-rozmerné dáta. V takýchto dátach je množstvo lokálnych zhlukov, čo môže spôsobiť konvergenciu k lokálnemu extrém.

Aplikácie Mean shift

Mean shift algoritmus má široké využitie, najmä v počítačovom videní, v oblastiach ako segmentácia, sledovanie objektov (tracking) a pod. Dáta tu nebývajú mnohorozmerné (najčastejšie je to farebný rozsah obrazu).

Mean shift je primárne algoritmus na hľadanie módov, ale je vhodný aj na identifikáciu zhlukov dát. Počet zhlukov je daný počtom módov.

Nevyžaduje informáciu o počte a tvare zhlukov. Je teda vhodný na hľadanie zhlukov neznámeho počtu a tvarov.

K-means algoritmus - zhukovací algoritmus

Je to jeden z najrozšírenejších zhukovacích algoritmov. Je jednoduchý, rýchly a efektívny.

Vyžaduje splnenie dvoch predpokladov:

- Známy počet zhlukov
- Kruhový (príp. eliptický) tvar zhlukov – stred (centroid) určuje zhluk

Cieľom je pospájať do zhlukov prvky množiny, ktoré sú si navzájom čo najviac podobné.

Zároveň platí, že prvky zaradené v rôznych zhlukoch sa čo najviac navzájom líšia.

Na výpočet podobnosti (resp. odlišnosti) prvkov používame miery vzdialenosti (napr. Euklidovská vzdialenosť).

Algoritmus

1. Náhodne vyber prvky množiny ako centroidy (stredy zhlukov).
2. Pre každý bod množiny nájdí najbližší centroid a následne tento bod zarad' do zhľuku patriaceho príslušnému centroidu.
3. V jednotlivých zhľukoch vypočítaj nové stredy (centroidy). Typicky je to priemer bodov v zhľuku.
4. Opakuj kroky 2. a 3. Dovtedy, kým sa preskupujú body medzi zhľukmi.

Porovnanie Mean shift a K-means

K-means je veľmi citlivý na počiatočnú inicializáciu. Nevhodná inicializácia môže predĺžiť čas konvergence, ale môže viesť aj nesprávnemu rozdeleniu do zhlukov.

Mean shift je vysoko odolný voči rôznym inicializáciám.

K-means je veľmi citlivý na „outliers“ - osamotené body množiny. Mean shift nie je na ne zvlášť citlivý.

K-means je v porovnaní s Mean shift algoritmom rýchly.

Klasifikácia verzus zhlukovanie (clustering)

Klasifikácia - zatriedovanie dát do tried (classes).

Triedy, do ktorých sa dáta zadeľujú, boli vytvorené na základe trénovacích dát – jednotlivé kategórie sú teda dané vopred (supervised learning).

Zhlukovanie – cieľom je vytvoriť z dát zhluky tak, aby body v zhlukoch mali rovnaké alebo aspoň podobné vlastnosti. (unsupervised learning). Žiadne trénovacie dáta sa nepoužívajú.

Hierarchický clustering – vytvorenie hierarchie vzájomne súvisiacich objektov alebo zhlukov

- (iteračný rozdeľovací algoritmus) – rozdelenie podľa vlastností (K-means)