



Extrakce a zpracování příznaků pro automatickou klasifikaci bitmapových obrázků

Pavel Surynek a Ivana Lukšová

Matematicko-fyzikální fakulta
Univerzita Karlova v Praze

Úloha klasifikace bitmapových obrázků

- ▶ Chceme klasifikovat bitmapové obrázky
 - ▶ podle charakteristik vyjádřených v přirozeném jazyce
 - ▶ automatickým procesem
 - ▶ PŘ.: z fotografií z dovolené vybrat ty, které zobrazují **krajinu**
- ▶ Formální specifikace klasifikační úlohy
 - ▶ Konečná množina bitmapových obrázků $\mathcal{I}$
 - ▶ Konečná množina klasifikačních tříd $\mathcal{K}$
 - ▶ pro $t \in \mathcal{K}$ je dána charakterizace $d(t)$ třídy t v přirozeném jazyce (např.: „obrázek zobrazuje krajinu“)
 - ▶ Správná klasifikace množiny obrázků $\mathcal{I}$ je definována vzhledem k fixnímu uživateli pomocí zobrazení c
 - ▶ $c: \mathcal{I} \rightarrow 2^{\mathcal{K}}$, že $\forall I \in \mathcal{I} \quad \forall t \in c(I) \quad \mathbf{d(t) \text{ dobře charakterizuje } I}$
- ▶ Chceme počítat $\mathbf{c'}$, které se **co nejvíce shoduje s c**



Zvolená metoda


► Základní použité komponenty

► Rozhodovací strom

- vektoru hodnot atributů přiřazuje „rozhodnutí“
- v našem případě bude strom rozhodovat o náležení do (jedné) klasifikační třídy $t \in \mathcal{K}$

► Extrakce atributů ze vstupního obrázku

- barevný bitmapový obrázek o rozměrech $w \times h$ pixelů představuje atributový vektor velikosti $w \times h$
- počet atributů budeme chtít **omezit** a do jednoho atributu budeme chtít **zahrnout více informací**
- vyvinuli jsme metody pro extrakci důležitých atributů
 - Př.: ostrost, barevnost, výskyt přímých linií, výskyt hran



Klasifikační třídy (zvolené pro vývoj metody)

▶ Umělecké obrazy

▶ Krajiny



▶ Makro objekty



▶ Fotografie



▶ Budovy



Výběr atributů a jejich extrakce

- ▶ Vhodné atributy vzhledem ke klasifikovaným třídám:
 - ▶ atributy založené na **barevné informaci** (př.: počet barev)
 - ▶ odlišování uměleckých obrazů a fotografií
 - ▶ atributy založené na **histogramu** (př.: kontrast)
 - ▶ důležité pro odlišení krajin a makro objektů
 - ▶ atributy založené na **hranové informaci** (př.: přímé linie)
 - ▶ důležité pro odlišení budov od ostatních klasifikačních tříd
- ▶ Sadu používaných atributů lze snadno rozšířit
- ▶ Pro každý atribut byla vyvinuta technika pro jeho extrakci:
 - ▶ relativně přímočaré pro jednoduché atributy (barvy, histogram)
 - ▶ komplexnější techniky pro extrakci atributů založených na hranové informaci



Barevná informace


▶ Příklady atributů založených na barevné informaci

▶ Počet barev

- ▶ u kresleného obrázku lze očekávat nízký počet barev

▶ Barevná paleta

- ▶ pravidelné rozdělení RGB krychle na 64 menších krychlí



Histogram a kontrast

- ▶ Atributy založené na histogramu:

- ▶ **low-key** obrázek
- ▶ **mid-key** obrázek
- ▶ **high-key** obrázek






- ▶ Lze také definovat kontrast:

- ▶ podle **Michelsona**
- ▶ podle **Webera**



- ▶ Používáme také tzv. **lokální kontrast**:

- ▶ kontrast v rámci omezené oblasti





Hranová informace

- ▶ Potřebujeme získat explicitní reprezentaci úseček vyskytujících se obrázku
 - ▶ Pak lze odvodit další atributy
 - ▶ výskyt **pravých úhlů**
 - ▶ statistické **rozdělení délek úseček**
- ▶ Algoritmus používající několik transformací:
 - ▶ (i) na vstupní obrázek je aplikován hranový detektor založený na **konvoluci s Laplaceovým** operátorem
 - ▶ (ii) pomocí **Houghovy transformace** jsou nalezeny přímky v obrázku po provedení detekce hran
 - ▶ nechť $p(\rho, \vartheta)$ = počet bodů na přímce $\rho = x \cdot \cos(\vartheta) + y \cdot \sin(\vartheta)$
 - ▶ lokální maximum funkce $p(\rho, \vartheta)$ indikuje výskyt přímky



Implementace softwarového nástroje

- ▶ Implementace metod pro extrakci atributů
- ▶ Ruční anotace trénovací sady obrázků
 - ▶ tj. specifikace zobrazení $c: \mathcal{I} \rightarrow 2^{\mathcal{K}}$ pro trénovací sadu
- ▶ Učící fáze rozhodovacích stromů
 - ▶ pro každou třídu $t \in \mathcal{K}$ jeden rozhodovací strom
 - ▶ použita učící metoda **ID3**



Experimentální vyhodnocení (1)

► Úspěšnost klasifikace třídy **fotografie**

- nejdůležitější atribut: **barevná paleta**

	Počet obrázků	Správně klasifikované	Úspěšnost
Trénovací sada	155	154	99.35%
Sada A	297	243	81.82%
Sada B	405	300	74.07%

► Úspěšnost klasifikace třídy **umělecké obrázky**

- nejdůležitější atribut: **počet lokálních maxim v histogramu**

	Počet obrázků	Správně klasifikované	Úspěšnost
Trénovací sada	104	104	100.00%
Sada A	297	251	84.51%
Sada B	405	331	81.73%

Experimentální vyhodnocení (2)

► Úspěšnost klasifikace třídy **budovy**

► nejdůležitější atribut: **počet pravých úhlů**

	Počet obrázků	Správně klasifikované	Úspěšnost
Trénovací sada	104	104	100.00%
Sada A	297	232	78.11%
Sada B	405	350	86.42%

► Úspěšnost klasifikace třídy **makro objekty**

► nejdůležitější atribut: **lokální kontrast**

	Počet obrázků	Správně klasifikované	Úspěšnost
Trénovací sada	118	118	98,89%
Sada A	297	259	87.20%
Sada B	405	295	72.84%

Závěr a budoucí práce

- ▶ Podařilo se navrhnout a implementovat relativně úspěšnou metodu pro klasifikaci bitmapových obrázků
 - ▶ extrakce **výstižných atributů**
 - ▶ **rozhodovací stromy**
 - ▶ úspěšnost **75%-85%**
- ▶ Navržená metoda je snadno rozšiřitelná
 - ▶ přidávání **nových atributů** (pro zpřesnění klasifikace)
 - ▶ přidávání **nových klasifikačních tříd**
- ▶ Budoucí práce
 - ▶ Vyzkoušet alternativní učící algoritmy pro rozhodovací stromy (například **C4.5**, ...)
 - ▶ Provést experimentální vyhodnocení vůči konkurenčním systémům (např. se systémem MUFIN image search)
 - ▶ Spustit klasifikaci obrázků systém on-line