

TEXTURE-BASED OBJECT RECOGNITION

Jiří Hutárek

Master Degree Programme (2), FIT BUT

E-mail: xhutar01@stud.fit.vutbr.cz

Supervised by: Michal Španěl

E-mail: spanel@fit.vutbr.cz

ABSTRACT

The main subject of this paper is a texture classification and texture-based object recognition. The system for the texture classification is implemented by using two different classification methods (SVM, ANN) and LBP as a texture feature. Comprehensive texture database is employed to test the performance of examined methods (including influence of various colour spaces and lighting conditions) and finally, the system is put to use on a real-world application—the segmentation of aerial photos.

1 ÚVOD

Textury lze velmi dobře využít v klasifikaci i segmentaci obrazu. Zde představím systém, který pro extrakci texturních příznaků využívá metodu *local binary patterns* (LBP) [1]. Takto získané příznaky jsou pak klasifikovány pomocí umělé neuronové sítě (ANN) a support vector machine (SVM). Praktické výsledky činnosti systému budou demonstrovány na segmentaci leteckých snímků.

2 LOCAL BINARY PATTERNS A KLASIFIKACE TEXTUR

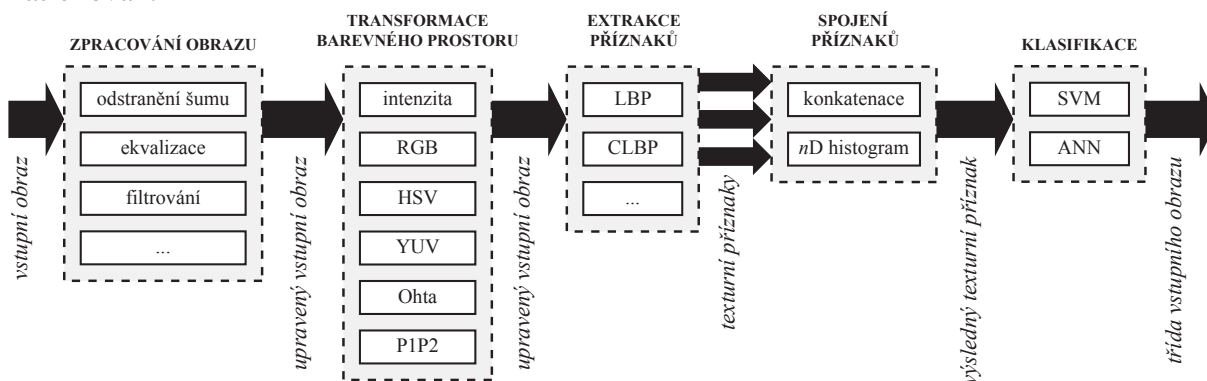
Původní varianta této metody pro extrakci texturních příznaků pracuje s intenzitami obrazu a její princip je jednoduchý: Pro každý bod obrazu je pomocí prahování a váhování bodů v jeho okolí vytvořen LBP kód, texturním příznakem je pak histogram LBP kódů všech bodů daného obrazu [2]. Tato metoda je výhodná díky své výpočetní efektivitě a robustnosti—je invariantní vůči rotaci i změnám osvětlení. Existuje také celá řada modifikací, z nichž pro tento příspěvek významná je varianta využívající barevnou informaci (CLBP).

3 SYSTÉM PRO KLASIFIKACI TEXTUR A SEGMENTACI OBRAZU

Blokové schéma systému je na obrázku 1. Jedná se o vysoce modulární systém a jeho činnost v konfiguraci pro klasifikaci neznámých obrazů je následující:

Vstupní obraz může být podle situace upraven některou z metod zpracování obrazu. Dále je provedena transformace barevného prostoru, protože v jiném prostoru mohou být výsledky klasifikace lepší. V dalším bloku jsou pak extrahovány zvolené texturní příznaky. Pokud bylo zvoleno více variant, je nutné je v následujícím bloku spojit do jediného příznaku, buď prostou

konkatenací dílčích histogramů, nebo vytvořením n -rozměrného histogramu. Tento výsledný texturní příznak je pak předán klasifikátoru, který obraz zařadí do jedné ze tříd, pro které byl natrénován.




Obrázek 1: Blokové schéma systému pro klasifikaci textur (fáze klasifikace).

Učení systému probíhá podobně, ovšem s tím rozdílem, že na vstupu je kromě obrazu navíc i jeho klasifikace a výstupem je natrénovaný klasifikátor. Segmentace obrazu je realizována pomocí dělení vstupního obrazu na vzájemně se překrývající okna, kdy pro každé okno je výše popsaným systémem určena jeho třída. Okna, resp. jejich klasifikace jsou pak spojeny do výsledného segmentovaného obrazu.

4 DOSAŽENÉ VÝSLEDKY

Pro testování systému byla použita obrazová data z databáze Outex [3]. Jedním z testů bylo srovnání klasifikačních metod. Z hlediska úspěšnosti klasifikace byl výrazně lepší klasifikátor využívající SVM (průměrná úspěšnost klasifikace 79,7 %, ANN 71,0 %). SVM se také lépe vyrovnává s nárůstem počtu klasifikovaných tříd a je jednodušší na nastavení parametrů (jejichž hledání lze navíc automatizovat)—je tedy celkově výhodnější.


Druhou zkoumanou oblastí byly barevné LBP. LBP příznaky byly v tomto případě vyhodnoceny v každém kanále zvlášť a výsledný příznak pak tvořila konkatence dílčích histogramů. Zde se ukázal zásadní vliv osvětlení na úspěšnost klasifikace pomocí barevných LBP. U homogenního



Obrázek 2: Úspěšnost klasifikace v závislosti na osvětlení pro různé barevné prostory.

osvětlení bylo barevnými LBP dosaženo vždy lepších výsledků, než u původní varianty, přičemž výsledek v barevném prostoru s nejlepší klasifikací (HSV) se od výsledku pořízeného pomocí základních LBP liší velmi výrazně. Naopak v případě nehomogenního osvětlení bylo pořadí výsledků přesně opačné (s výjimkou barevného prostoru P1P2), kdy rozdíl krajních výsledků byl ještě výraznější. Z těchto zjištění tedy můžeme učinit závěr, že barevné LBP je možné použít pouze při konstantním osvětlení. V opačném případě je mnohem úspěšnější (a také rychlejší) základní varianta LBP.

Konečně výsledek aplikace systému na reálný problém je na obrázku 3. V originálním snímku (vlevo) jsou pomocí textur rozpoznány zemědělské plochy (bíle), lesy (šedě) a zástavba (černě). Jelikož v tomto případě není k dispozici referenční výsledek, lze úspěšnost klasifikace posoudit pouze kvalitativně.



Obrázek 3: Výsledek segmentace leteckého snímku.

5 ZÁVĚR

Implementovaný systém pro klasifikaci textur a segmentaci obrazu byl komplexně otestován na rozsáhlé obrazové databázi za použití dvou různých klasifikátorů a různých metod extrakce texturních příznaků. Ukázalo se, že osvětlení a použitý barevný prostor mají na úspěšnost klasifikace zásadní vliv. Přesnost klasifikace reálných dat (letecké snímky) je možné zlepšit zejména pomocí většího objemu trénovacích dat.

Systém lze dále rozvíjet nasazením dalších variant texturních příznaků a zlepšováním klasifikátoru, přičemž nezanedbatelnou částí tohoto výzkumu je experimentální hledání co nejlepších parametrů systému.

REFERENCE

- [1] MÄENPÄÄ, T.: *The local binary pattern approach to texture analysis – extensions and applications*. University of Oulu, 2003, ISBN 951-42-7076-2.
- [2] OJALA, T.: *A comparative study of texture measures with classification based on feature distributions*. Pattern Recognition, 1996: s. 51–59.
- [3] OJALA, T.; MÄENPÄÄ, T.; PIETIKÄINEN, M.; aj.: *Outex – New framework for empirical evaluation of texture analysis algorithms*. Pattern Recognition, 2002: s. 701–706.