

Studentská Vědecká Konference 2011

KLASIFIKACE TEXTUR S VYUŽITÍM METODY LBP

Jan VLK¹

1 ÚVOD

Textura charakterizuje z hlediska vizuálního zpracování obrazu strukturu objektu, s její pomocí se dají dobře popisovat vlastnosti povrchů materiálů, které by běžnou řečí mohly být popsány např. jako hrubé, hladké, zrnité atd. Také si ji můžeme představit jako vzor na povrchu objektu. Z tohoto důvodu je texturní popis vhodný pro rozpoznávání obrazů v oblasti počítačového vidění. Spektrum oblastí aplikace texturního rozpoznávání je velmi široké, od ryze technických odvětví materiálového inženýrství až po uplatnění v biologii a lékařství.

Tato práce se zabývá využitím metody *local binary patterns* (dále jen LBP), při klasifikaci textur.

2 LBP A KLASIFIKACE

LBP je jednoduchá metoda pro extrakci texturních příznaků. Obraz je nejprve převeden do šedotónové reprezentace, pro každý pixel (x_c, y_c) obrazu se zpracovává jeho okolí a to podle následujícího vzorce, kde P je počet pixelů v okolí centrálního pixelu a R je poloměr neboli euklidovská vzdálenost centrálního a sousedního pixelu, g_p, g_c jsou hodnoty jejich jasů. Pro naše potřeby použijeme operátor $LBP_{P,R}$, tudíž uvažujeme tzv. osmiokolí sledovaného pixelu.

$$LBP_{P,R}(x_c, y_c) = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p; \quad s(x) = \begin{pmatrix} 1 & x \geq 0 \\ 0 & x < 0 \end{pmatrix} \quad (1)$$

Každý pixel obrazu je reprezentován binárním číslem, vzniká tedy tzv. LBP obraz o stejných rozměrech, které měl původní obraz [2]. Z tohoto LBP obrazu se vypočte histogram, vzniká tak vektor příznaků, který zredukujeme pomocí algoritmu *uniform patterns*, jenž vybere pouze ta binární čísla, která mají přechod 0/1 nebo 1/0 roven 2. Podrobně je algoritmus popsán v práci [3]. Tento vektor můžeme použít ke klasifikaci.

Samotnou klasifikaci realizujeme pomocí Bayesova klasifikátoru, který bude nutno nejprve natrénovat. Pro jednoduchost uvažujeme klasifikátor s učitelem, tudíž máme apriorní znalost o tom, která trénovací data patří do které třídy. Klasifikujeme vstupní vektor \mathbf{x} do R tříd označených indikátory $\omega_1, \omega_2 \dots \omega_R$. Vektor příznaků \mathbf{x} zařadíme do té třídy ω^* , pro níž platí

$$\omega^* = \arg \max_r p(\mathbf{x} | \omega_r) \quad (2)$$

kde $p(\mathbf{x} | \omega_r)$ je podmíněná hustota pravděpodobnosti a vyjadřuje pravděpodobnost, že vektor příznaků \mathbf{x} patří do třídy ω_r . Budeme uvažovat, že podmíněná hustota pravděpodobnosti se řídí normálním rozdělením, tudíž bude ve tvaru


¹ Jan Vlk, student navazujícího studijního programu Aplikované vědy a informatika, obor Kybernetika a řídicí technika, specializace Umělá inteligence, e-mail: vlkjan@students.zcu.cz

$$p(x|\omega_r) = \frac{1}{\sqrt{(2(\pi)^N)\|\Sigma\|_r}} \exp(-\frac{1}{2}(x - \mu_r)^T \Sigma_r (x - \mu_r)) \quad (3)$$

kde N je počet prvků příznakového vektoru \mathbf{x} , μ_r je střední hodnota normálního rozdělení a Σ_r je jeho kovarianční matice. Pro natrénování klasifikátoru potřebujeme znát parametry μ_r a Σ_r , které získáme statistickým rozbořem trénovacích dat [1]

3 IMPLEMENTACE

Algoritmus LBP i Bayesův klasifikátor jsme implementovali v prostředí Matlab. Objektem klasifikace byly mikroskopické snímky polymerů, které jsme zařazovali do deseti tříd. Pro každou třídu jsme použili 90 obrazů k natrénování klasifikátoru a deset obrazů jsme použili jako testovací data. Tabulka Tab. 1 udává, kolik procent testovaných dat bylo zařazeno do správné třídy.



Obř. 1: Ukázka mikroskopických snímků různých polymerů

třída	procentuální úspěšnost	třída	procentuální úspěšnost
ω_1	80%	ω_6	70%
ω_2	60%	ω_7	90%
ω_3	80%	ω_8	30%
ω_4	60%	ω_9	70%
ω_5	50%	ω_{10}	100%

Tab. 1: Tabulka úspěšnosti klasifikace obrazu

4 ZÁVĚR

Experimenty na obrazových datech prokázaly, že metoda LBP je vhodná pro extrakci příznaků z textur s použitím následné klasifikace. Další práce by se mohla týkat zkoumání různých LBP operátorů (jiný poloměr a počet sousedních pixelů) případně použitím jiných metod klasifikace (např. umělé neuronové sítě, support vector machine). Kompletní algoritmus by jistě našel využití i v úlohách segmentace obrazu. Lepších výsledků by mohlo být dosaženo vyšším počtem trénovacích dat.

LITERATURA

- [1] Havlík J., 2008. *Implementace Bayesova klasifikátoru a diskriminačních funkcí v prostředí Matlab*. ČVUT v Praze
- [2] MÄENPÄÄ, T. *The Local Binary Pattern Approach to Texture Analysis - Extensions and Applications* University of Oulu 2003
- [3] Pasáček V., 2009. *Charakteristiky 2D textur*. Bakalářská práce, VUT Brno.