

Využití metod zpracování obrazu pro určování fyzikálních vlastností polymerů

Jan Vlk¹

1 Úvod

Motivací k napsání této práce bylo zkoumání fyzikálních vlastností (tvrdost, světelná propustnost, odrazivost, atd.) polymerových skel do automobilových světlometů z hlediska jejich mikroskopické struktury. V současnosti existuje mnoho typů mechanických či chemických testů, které dávají informaci o různých fyzikálních vlastnostech. Tyto testy jsou však náročné na čas i na použitý materiál. Představa rozpoznání fyzikálních vlastností ve zlomcích sekundy a pouze s použitím mikroskopu s fotoaparátlem je v současnosti neřešený problém. K dispozici budeme mít několik mikroskopických snímků různých typů polymerů. Tyto obrazy vykazují charakter textur a tudíž přistoupíme k jejich analýze pomocí metod texturního popisu obrazů. Určení fyzikálních vlastností se v podstatě rovná zařazování obrazů do tříd, tudíž budeme tento problém řešit, jako úlohu klasifikace obrazů a v předložené práci budeme testovat několik metod extrakce příznaků v kombinaci s algoritmy strojového učení.

2 Algoritmy extrakce příznaků a klasifikace

Abychom mohli rozpoznávat mikroskopickou strukturu polymerů (resp. jejich fyzikální vlastnosti) musíme jí vhodně popsat. K tomuto účelu slouží metody extrakce texturních příznaků. Rozpoznávání polymerových struktur zajišťují algoritmy strojového učení neboli klasifikátory. V této práci budeme testovat různé metody popisu textur v kombinaci s několika klasifikátory. Testované algoritmy budou deskriptory založené na výpočtu matice sousednosti, na počtu opakování jasů a na metodě local binary pattern (LBP) a klasifikátory support vector machine (SVM), Bayesův klasifikátor a klasifikátor dle k-nejbližších sousedů.

Matice sousednosti (co-occurrence matrix, COOM) popisuje počty shodných jasů v určitých směrech oddělených určitou délkou. Tuto matici je tedy možné konstruovat v závislosti na směru ($0^\circ, 45^\circ, 90^\circ, 135^\circ$) a délce mezi pixely se shodným jasnem. Vektor příznaků vypočtený na základě matice sousednosti bude obsahovat hodnoty kontrastu, korelace, energie, homogenita, které jsou dle [Hlaváč (2008)] nejvhodnějšími deskriptory pro texturní obrazy.

Metoda Grey level run length (GLRL) zkoumá počty opakujících se jasů v obraze. Hrubé textury obsahují velké oblasti se stejným jasnem, v jemných se naopak vyskytují malé plochy opakujících se jasů (tzv. Runs, neboli běhy). Nezáleží na poloze těchto běhů, pouze na jejich četnostech [Pons (2004)]. Jako příznaky jsme zvolili Short run emphasis, Long run emphasis, Gray level nonuniformity a Run length nonuniformity a Run percentage.

LBP je jednoduchá metoda pro extrakci texturních příznaků. Pro každý pixel obrazu (x_c, y_c) se zpracovává jeho okolí podle rovnice (1), 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 $LBP_{1,8}$, tudíž uvažujeme tzv. osmiokolí sledovaného pixelu. Z vytvořeného LBP obrazu, jehož rozměry jsou shodné s původním obrazem,

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

Příznaky	Klasifikátory		
	SVM	K-NN	Bayes
COOM	73.67	44.33	69.00
GLRL	82.67	56.33	81.67
LBP	77.33	74.67	82.00

Tabulka 1: Vyhodnocení přesnosti klasifikátorů [%]

vypočteme histogram, jenž je zároveň vektorem příznaků [MAENPAA (2003)].

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

Bayesův klasifikátor nachází svůj základ v klasifikačních algoritmech, řídicích se dle kritéria minimální chyby a jeho nespornou výhodou je jednoduchost nastavení, ovšem za cenu ztráty charakteru dat (např. uvažujeme data s normálním rozložením).

Klasifikátor support vector machine (dále SVM) hledá v obrazovém prostoru takovou nadrovinu, která optimálně rozděluje obrazy do dvou tříd. Základní podmínka pro konstrukci nadroviny je, aby její vzdálenost od nejbližších obrazů obou tříd byla co největší. Tyto nejbližší obrazy nazýváme podpůrné vektory (resp. support vectors).

3 Vyhodnocení výsledků

Častým problémem při rozpoznávání obrazu je nedostatek dat k natrénování klasifikačních algoritmů. Pro potřeby testování jsme rozdělili každý snímek na 100 menších podsímků, tak vznikla data k natrénování klasifikátorů (70% snímků z každé třídy) a k jejich následnému testování (30% snímků). Tabulka 1 uvádí procentuální úspěšnost kombinací různých algoritmů.

V této práci jsme vyhodnocovali testy pro parametrizaci a klasifikaci mikroskopických snímků polymerů za účelem rozpoznávání jejich fyzikálních vlastností na základě mikroskopické struktury. Nejlepších výsledků ve všech testech dosahovala kombinace algoritmů LBP a Bayesova klasifikátoru. Překvapivě dobrých výsledků dosáhly metody počtu opakování jasů (GLRL) v kombinaci s SVM i Bayesovým klasifikátorem. Do budoucna by bylo vhodné zaměřit se na propojení znalostí fyziky polymerů s algoritmy zpracování obrazu a na implementaci systému pro rozpoznávání fyzikálních vlastností polymerů v praxi.

Poděkování

Tato práce byla podpořena grantem SGS-2010-054: "Inteligentní metody strojového vnímání a porozumění".

Literatura

- Šonka, M.-Hlaváč, V.-Boyle, R.: *Image Processing, Analysis and Machine Vision*. Thomson 2008
- Pons, M.-Belaroui, K-Simer, N.: *Characterisation of grinding media wear by visual texture.*, Elsevier 2004.
- MÄENPÄÄ, T.: *The Local Binary Pattern Approach to Texture Analysis - Extensions and Applications* University of Oulu 2003