

TEXTURAL ANALYSIS OF RETINAL NERVE FIBRE LAYER IN COLOUR FUNDUS IMAGES

Adam Novotný

Master Degree Programme (2), FEEC BUT

E-mail: xnovot92@stud.feec.vutbr.cz

Supervised by: Jan Odstrčilík

E-mail: xodstr02@stud.feec.vutbr.cz

ABSTRACT

This paper describes new method of the retinal nerve fiber layer loss detection in the colour fundus images of the human eye. The proposed textural analysis utilizes LBP - Local Binary Patterns. This approach is characterized especially by the computational simplicity, insensitivity to monotonic changes of illumination and the rotation-invariant properties [1]. Image histograms of the LBP distribution are used to gain several textural features aimed to classify healthy and glaucomatous tissue of the retinal nerve fiber layer.

1. ÚVOD

Glaukom (zelený zákal) je onemocnění oka, které se projevuje postupným odumíráním gangliových buněk sítnice a vláken zřakového nervu způsobující tak částečnou, nebo v pokročilejších stádiích, i trvalou slepotu. Pro efektivní léčbu glaukomu je zcela zásadní odhalit poškození vrstvy nervových vláken (VNV) co nejdříve. Dodnes neexistuje žádná metoda, která by z analýzy retinálních fotografií dokázala automaticky a spolehlivě diagnostikovat zmíněné poškození VNV.

Tento příspěvek prezentuje metodu texturní analýzy pro automatickou detekci výpadků ve VNV v barevných fotografiích sítnice pomocí lokálních binárních vzorů (LBP – Local Binary Patterns) [1].

2. METODA


Základem metody je využití uniformního rotačně-invariantního LBP operátoru sloužícího k popisu lokální textury reprezentující VNV na snímku sítnice. Texturu v okolí pixelu (x_c, y_c) je možno popsat LBP kódem, který je dán rovnicí (základní rotačně variantní verze) [1]:

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

kde g_c je hodnota centrálního pixelu (x_c, y_c) lokálního rotačně symetrického okolí a $g_p (p = 0, \dots, P-1)$ jsou hodnoty o počtu P rovnoměrně uspořádaných pixelů po kružnici o poloměru $R (R > 0)$ společně formující kruhové okolí centrálního pixelu [1].

2.1. KLASIFIKACE

K analýze retinálních snímků byly použity přístupově dvě modifikace LBP; obě jsou znázorněny na Obrázku 1. V obou případech je využíván rotačně invariantní, uniformní operátor $LBP_{16,2}$. V prvním případě je ze vstupního obrazu počítána LBP distribuce (horní větev Obrázku 1), následně je vytvořen jednoduchý šedotónový histogram a z tohoto histogramu je vypočteno 6 texturních příznaků: střední hodnota, rozptyl, šikmost, křivost, energie a entropie. V druhém případě (spodní větev Obrázku 1) je LBP distribuce doplněna o výpočet lokálního kontrastu (C) [1]. Z této dvojrozměrné LBP/ C distribuce je vypočítán sružený histogram a z něj je získáno dalších 14 texturních příznaků, blíže definovaných Haralickem v [2].



Obrázek 1: Blokové schéma prezentované metody

Celkem je tedy získáno 20 příznaků pro popis textury VNV tvořících jeden příznakový vektor - 6 pro jednoduchý histogram a 14 pro sružený histogram. Tyto příznaky byly pro účely následné klasifikace seřazeny ve smyslu jejich relevance pomocí algoritmu založeném na výpočtu jejich vzájemné informace; blíže v [4].

Takto seřazené příznaky byly testovány za účelem klasifikace mezi zdravou a nemocnou tkání VNV na fotografiích sítnice (3504×2336 pixelů) pořízených digitální fundus kamerou CANON CF-60 UVi s vestavěným autofluorescenčním modro-zeleným filtrem. K analýze byl využit aritmetický průměr zelené a modré složky RGB snímku, protože bylo již dříve ověřeno v [3], že tato kombinace představuje nejlepší řešení z pohledu viditelnosti VNV. K dispozici bylo 18 snímků sítnice zdravých pacientů a 10 snímků pacientů s glaukomem. Z těchto snímků byly za účelem testování metody ručně vybrány vzorky textury VNV o velikost 41×41 pixelů. Tyto vzorky byly rozděleny do 3 kategorií:

- **Skupina A** – 282 vzorků bez výpadku ve VNV – zdravá tkáň u nemocného oka,
- **Skupina B** – 326 vzorků s výpadkem ve VNV – nemocná tkáň u nemocného oka,
- **Skupina C** – 566 vzorků bez výpadku ve VNV – zdravá tkáň u zdravého oka (kontrolní skupina vzorků).


Z vytvořené testovací databáze byl proveden experiment vyhodnocující schopnost klasifikace jednotlivých vzorků VNV do uvedených tří skupin. Schopnost klasifikace byla vyhodnocena pro všechny možné kombinace tříd (A-B, A-C, C-B) a s postupným přidáváním příznaků dle jejich relevance. Ke klasifikaci byly využity dva klasifikátory: Ho-Kashyap a Bayesovský; více o teorii v [5]). K trénování klasifikátorů bylo použito 60 % náhodně vybraných vzorků a zbylých 40 % bylo použito k testování. Proces trénování-testování byl opakován 100krát a z jednotlivých běhů byla vypočítána průměrná klasifikační chyba, viz Tabulka 1.

2.2. DISKUSE VÝSLEDKŮ

Nejlepší výsledky klasifikace byly dosaženy při použití prvních sedmi příznaků v příznakovém vektoru najednou a s použitím Ho-Kashyap klasifikátoru. Klasifikační

chyba při snaze separovat třídy A-B a B-C, což odpovídá problému při detekci výpadku VNV v reálném snímku (Obrázek 2), nepřevyšuje 3 %.

f_i	"Ho-Kashyap"			"Bayesovský"		
	A-B [%]	B-C [%]	A-C [%]	A-B [%]	B-C [%]	A-C [%]
f_1	10.3 ± 1.4	1.4 ± 0.5	11.8 ± 1.4	10.3 ± 1.7	1.3 ± 0.5	12.6 ± 1.3
$f_1 \dots f_2$	5.4 ± 1.1	1.4 ± 0.4	12.1 ± 1.4	5.3 ± 1.2	1.1 ± 0.5	13.3 ± 1.2
$f_1 \dots f_3$	5.3 ± 1.1	1.3 ± 0.4	12.1 ± 1.2	6.0 ± 1.1	1.2 ± 0.5	13.6 ± 1.4
$f_1 \dots f_4$	4.2 ± 1.1	1.2 ± 0.5	11.6 ± 1.4	5.4 ± 1.2	1.2 ± 0.5	12.9 ± 1.4
$f_1 \dots f_5$	3.3 ± 0.9	0.7 ± 0.4	10.9 ± 1.3	3.8 ± 1.1	0.7 ± 0.4	12.9 ± 1.7
$f_1 \dots f_6$	3.1 ± 0.9	0.7 ± 0.3	11.1 ± 1.2	3.8 ± 0.9	0.8 ± 0.4	13.1 ± 1.6
$f_1 \dots f_7$	2.9 ± 0.9	0.6 ± 0.3	11.2 ± 1.3	3.3 ± 1.0	0.8 ± 0.4	12.9 ± 1.7
$f_1 \dots f_8$	2.9 ± 0.9	0.6 ± 0.3	11.1 ± 1.4	3.7 ± 0.9	0.8 ± 0.3	13.2 ± 1.8



Tabulka 1: Chyby klasifikace; index i odpovídá pořadí v příznakovém vektoru f_i ; nejlepší výsledky jsou zvýrazněny

Obrázek 2: Výsledek detekce výpadku ve VNV ve vybrané oblasti retinálního snímku

3. ZÁVĚR

Provedené experimenty ukázaly, že navržené rotačně invariantní LBP příznaky lze s úspěchem použít k automatické detekci výpadků ve VNV na fotografiích sítnice. Dosažené chyby klasifikace při testování dvěma klasifikátory jsou shrnuty v Tabulce 1 a výsledek detekce výpadku ve VNV v diagnosticky významné oblasti retinálního snímku pacienta s glaukomem je znázorněn na Obrázku 2. Je vidět, že oblasti výpadku ve VNV (označeno bílými šipkami – Obr. 2 vlevo) správně korelují s výsledkem automatické klasifikace (Obr. 2 vpravo). Dosažený výsledek detekce výpadku na Obr. 2 prezentuje možnost využití této metody pro diagnostiku glaukomu. V budoucnosti však bude nutné provést testování metody na větším počtu snímků a provést vyhodnocení její úspěšnosti.

LITERATURA

- [1] Mäenpää, T. The Local Binary Pattern Approach to Texture Analysis - Extensions and Applications, doctoral thesis. Oulu 2003; online <http://herkules oulu.fi/isbn9514270762/isbn9514270762.pdf>.
- [2] Haralick R. M, et al. Textural Features for Image Classification, IEEE Trans. on systems, man., and cybernetics, vol. smc-3, No. 6 November 1973.
- [3] Kolář R. Methods for image analysis and pattern recognition - Application to early glaucoma diagnosis, Dissertation, Dpt. of Biomedical Engineering. FECC, Brno University of Technology, Brno, Czech Republic, 2008.
- [4] Peng H, et al. Feature selection based on mutual information: Criteria of max dependency, max-relevance and min-redundancy, IEEE Trans. on Patt. Analys. and Mach. Intel. vol.27(8):1226-1238.
- [5] O. R, Hart E. P, Stork G. D. Pattern Classification. Wiley, New York 2001; ISBN: 0471056693.