

IMAGE OBJECT DETECTION USING HAAR-LIKE FEATURES

Jan Mašek

Master Degree Programme (2), FEEC BUT

E-mail: xmasek10@stud.feec.vutbr.cz

Supervised by: Radim Burget

E-mail: burgetrm@feec.vutbr.cz

Abstract: This article deals with the image object detection using Haar-like features. The text describes methods how to train and test an object detector. Created algorithms were integrated as plugin into the RapidMiner tool, which is widely used and known worldwide. Functionality was demonstrated on MRI images, where the temporomandibular joint discs were detected. The accuracy of the object detector was assessed using MRI images obtained from doctors. The best achieved accuracy was 66,7%.

Keywords: image processing, object detection, Haar-like features, MRI, temporomandibular joint disc, RapidMiner, Java

1 ÚVOD

V dnešní době se metody detekování objektů v obraze využívají v celé řadě oblastí. Běžný člověk se nejčastěji setká například s detekcí obličejů, nebo lidských postav v digitálních fotoaparátech nebo kamerách. Jednou z významných oblastí zpracování obrazů je zpracování biomedicínských snímků. Příkladem může být detekce čelistního kloubu ze snímků magnetické rezonance. Na základě detekce čelistního kloubu je možné změřit parametry chrupavky kloubu. Díky získaným parametrům je možné diagnostikovat nemoc jakou je porucha čelistního kloubu.

Hlavním přínosem práce je modifikace detektoru objektů v obraze o možnosti jeho trénování genetickými algoritmy. Testování natrénovaného detektoru probíhalo na snímcích čelistních kloubů, kde detektor dosáhl 66,7% přesnosti detekce s průměrnou rychlostí detekce jednoho snímku 30 ms. Všechny metody a algoritmy byly integrovány jako operátory do programu RapidMiner, který patří celosvětově mezi nepoužívanější programy pro dolování informací z báze dat.


2 DETEKTOR OBJEKTŮ V OBRAZE

Tato práce primárně vychází z objektového detektoru, který byl prvně představen P. Violou a M. Jonesem v roce 2001, a který se vyznačuje především svou rychlostí a přesností detekce. Vlastností detektoru je schopnost vyhledávat objekty s různými rozměry. Pro natrénování detektoru se využívá klasifikační algoritmus AdaBoost, který vybírá jednoduché klasifikátory a skládá je do kaskády na základě vstupní množiny negativních a pozitivních snímků. Jako jednoduché klasifikátory jsou použity Haarovy příznaky. Prahová hodnota klasifikátorů je určena s pomocí Matthewsova korelačního koeficientu C_M z rovnice 1, kde N_{TP} určuje počet správně klasifikovaných pozitivních snímků, N_{TN} počet správně klasifikovaných negativních snímků, N_{FP} počet falešně pozitivních snímků a N_{FN} počet falešně negativních snímků. Pro rychlou funkci detektoru je použit integrální obraz a kaskáda klasifikátorů. [1][3]

$$C_M = \frac{N_{TP} N_{TN} - N_{FP} N_{FN}}{\sqrt{(N_{TP} + N_{FP})(N_{TP} + N_{FN})(N_{TN} + N_{FP})(N_{TN} + N_{FN})}}. \quad (1)$$

2.1 TRÉNOVÁNÍ DETEKTORU

Trénovací množinou algoritmu AdaBoost jsou pozitivní snímky (obrázek 1a), které obsahují hledaný objekt a negativní snímky (obrázek 1b), které obsahují pozadí. Další etapou je vygenerování všech Haarových příznaků (189 664) pro velikost detekčního okna 24x24 pixelů. [1] V dalším kroku algoritmus AdaBoost vybírá určité množství slabých lineárních klasifikátorů tak, aby jejich lineární kombinací vznikl silný nelineární monolitický klasifikátor, který reprezentuje stupeň kaskády. Takto vzniklých silných klasifikátorů je možné použít více, v závislosti na počtu stupňů kaskády.



Obrázek 1: Ukázka trénovacích snímků.

2.2 IMPLEMENTACE GENETICKÝCH ALGORITMŮ PRO TRÉNOVÁNÍ DETEKTORU

Hlavní přínos této práce spočívá v použití genetických algoritmů pro trénování detektoru. Účelem těchto algoritmů je upravit stávající kaskádu klasifikátorů tak, aby měla co nejlepší přesnost detekce na trénovacích datech. To je provedeno náhodným rozmístěním klasifikátorů do stupňů kaskády. V dalším kroku následují úpravy prahových hodnot jednotlivých stupňů kaskády. [2]

2.3 TESTOVÁNÍ DETEKTORU


Pro detekci objektů je načten snímek spolu s natrénovanou kaskádou klasifikátorů. Detekční proces začíná nastavením velikosti a pozice detekčního okna ve vstupním snímku. Tímto vznikne pod-okno, na které je aplikována kaskáda klasifikátorů. Pokud pod-okno projde všemi stupni kaskády, tak jsou jeho souřadnice přidány do seznamu detekovaných oblastí. Takto je detekční okno posunuto přes celý obraz. Pak je v každé iteraci zvětšeno a opět posouváno. Po ukončení procesu je na výsledky detekce aplikováno sloučení vícenásobných detekcí stejného objektu do jedné detekce, která je nejvíce vypovídající. Nakonec jsou detekované oblasti zobrazeny ve vstupním snímku.

3 IMPLEMENTACE ALGORITMŮ DO PROSTŘEDÍ PROGRAMU RAPIDMINER

Všechny metody a algoritmy byly integrovány jako operátory do programu RapidMiner. Operátory jsou vytvořeny v programovacím jazyce JAVA a jsou součástí knihovny „Image Processing Extension“, která je vyvíjena na Ústavu telekomunikací výzkumnou skupinou Signal Processing Laboratory. Celkem bylo v rámci této práce vytvořeno 7 operátorů: pro načítání sady obrázků, vytváření trénovacích dat, natrénování kaskády klasifikátorů, testování kaskády klasifikátorů, zhodnocení úspěšnosti kaskády, detekci objektů v obraze a úpravu kaskády klasifikátorů.

4 VÝSLEDKY

Na základě popsaných algoritmů byl natrénován detektor čelistního kloubu. Na obrázku 2a je zobrazen vstupní snímek z magnetické rezonance. Dále jsou v něm zobrazeny všechny nalezené detekce (obrázek 2b) a nakonec jsou tyto detekce sloučeny v jednu nejvíce vypovídající (obrázek 2c). Pro trénování detektoru bylo použito 280 pozitivních a 300 negativních snímků. Následně byly na těchto



Obrázek 2: Detekce čelistního kloubu.

datech natrénovány dvě kaskády klasifikátorů: jedna byla natrénována bez použití genetických algoritmů (GA) a druhá s použitím GA. Přesnost detekce byla spočtena jako podíl mezi sumou správně detekovaných oblastí a sumou všech hledaných oblastí. V tabulce 1 jsou zobrazeny výsledky přesnosti detekce objektů na trénovacích a testovacích datech. Každá kaskáda byla testována dvěma způsoby: při prvním byly zobrazeny všechny detekce, takže ve výsledcích je kromě hodnoty přesnosti detekce také informace o počtu falešně pozitivních detekcí (N_{FP}). V druhém způsobu byla uvažována jen nejvýznamnější detekce, protože se předpokládá, že v celém snímku se nachází pouze jeden čelistní kloub. Z výsledků vyplývá, že kaskáda klasifikátorů, která byla trénována genetickými algoritmy, dosahuje vyšší přesnosti detekce z původních 41,7% na výsledných 66,7%.

Tabulka 1: Přesnost detekce natrénovaných kaskád klasifikátorů.

Snímky	s GA	s GA + N_{FP}	bez GA	bez GA + N_{FP}
trénovací (70)	70,0%	82,9% + 86	62,9%	92,9% + 344
testovací (12)	66,7%	100,0% + 18	41,7%	100,0% + 93

5 ZÁVĚR

Hlavním přínosem práce je modifikace stávajícího Viola–Jones objektového detektoru o možnosti jeho trénování genetickými algoritmy. S využitím této metody se podařilo vytvořit detektor čelistního kloubu s přesností 66,7%, což je o 25% více než za použití původní metody. Tento detektor je schopen pracovat se snímky s rozlišením 640x640 pixelů na běžném počítači v reálném čase. Zmíněný nástroj je v současné době součástí rozšíření RapidMineru, které je komerčně nabízeno v rámci spolupráce VUT a německé společnosti Rapid-I. Vytvořený algoritmus byl také již použit ve vědecké práci Dr. Manola Maragoudaka z „University of the Aegean“, kde byly detekovány některé body na sítnici oka. Dále byl algoritmus nasazen rakouskou firmou „Ditech“ pro vytvoření aplikace pro počítání osob v obchodě.

REFERENCE

- [1] Viola, P.; Jones, M. *Rapid Object Detection using a Boosted Cascade of Simple Features*. IEEE CVPR 2001, Vol. 1, pp. 511-518.
- [2] Goldberg, D. E. *Genetic Algorithms in Search, Optimization, and Machine Learning*. Reading, MA: Addison-Wesley, 1989.
- [3] Forsyth, D.; Ponce, J. *Computer Vision: A Modern Approach*. Prentice Hall; 2 edition (November 7, 2011).