

KLASIFIKÁCIA VIZUÁLNYCH SLOV POMOCOUPRAVENEJ GENETICKEJ PAMÄTE

Ing. Ján Kvak

FIIT STU


Školiteľ: doc. Ing. Ladislav Hudec, CSc.

14.4. 2014


PROBLÉM

- Rozpoznávanie obrazu pomocou lokálnych deskriptorov reprezentovaných reťazcami bitov (ORB, BRIEF, FREAK)
- Vytváranie vizuálnych slov
- Klasifikácia vizuálnych slov
- Požiadavky:
 - Rýchle rozpoznávanie
 - Veľké množstvo tried
- Potenciál použitia v obohatenej realite

ROZPOZNÁVANIE OBRAZU




ROZPOZNÁVANIE OBRAZU




BINÁRNE LOKÁLNE DESKRIPTORY

- BRIEF, ORB, BRISK, FREAK ...
- Reprezentujú bod binárnym reťazcom



A	B	C
1	0	0



A	B	C
0	1	0

VIZUÁLNE SLOVÁ


- Inšpirovaný systémami na vyhľadávanie dokumentov
- Analógia so slovami prirodzeného jazyka
- Vektorová kvantizácia deskriptorov do klastrov[1]
- Kvantizované lokálne príznaky[2]
- Klaster kľúčových bodov[3]
- Obrázok = dokument

[1] J. Sivic and A. Zisserman, "Video Google: a text retrieval approach to object matching in videos," *Proc. Ninth IEEE Int. Conf. Comput. Vis.*, vol. 2, no. lccv, pp. 1470–1477, 2003.

[2] J. Qin and N. H. C. Yung, "Scene categorization via contextual visual words," *Pattern Recognit.*, vol. 43, no. 5, pp. 1874–1888, May 2010.

[3] J. Yang, Y.-G. Jiang, A. G. Hauptmann, and C.-W. Ngo, "Evaluating bag-of-visual-words representations in scene classification," *Proc. Int. Work. Work. Multimed. Inf. Retr. - MIR '07*, pp. 197–206, 2007.

VIZUÁLNE SLOVÁ - PRINCÍP




VIZUÁLNE SLOVÁ - ALGORITMUS

- Detekcia lokálnych príznakov
- Opísanie lokálnych príznakov deskriptormi
- **Generovanie slovníka**
- **Rozpoznanie vizuálnych slov v obrázkoch**
- Reprezentácia obrázka ako kombinácie slov (*bag of visual words*)
- Rozpoznanie obrázka na základe kombinácie vizuálnych slov

VIZUÁLNY SLOVNÍK

- Množina vizuálnych slov
- Používa sa klastrovanie (napr. K-Means)



[1] G. Csurka, C. R. Dance, L. Fan, J. Willamowski, C. Bray, and D. Maupertuis, "Visual Categorization with Bags of Keypoints," *Work. Stat. Learn. Comput. Vis. ECCV*, vol. 1, p. 22, 2004.

[obrázok] J. Sivic and A. Zisserman, "Video Google: a text retrieval approach to object matching in videos," *Proceedings Ninth IEEE International Conference on Computer Vision*, no. lccv, pp. 1470–1477 vol.2, 2003.


PO VYTVORENÍ - KLASIFIKÁCIA

- Ako zistíme, aké vizuálne slovo sme v obraze našli?
- Porovnanie s každým vizuálnym slovom
- Klasifikácia obrázkov
 - *Naive Bayes*
 - *Hierarchical Bayes model*
 - *Support Vector Machine*
 - Pri deskriptore BRIEF – *Semi-Naive Bayes*
- Nutnosť rýchleho rozpoznania

GENETICKÁ PAMÄŤ

- Kombinácia Riedko distribuovanej *pamäte* (*Sparse distributed memory, SDM*) a Genetických algoritmov
- Využitá na predpovedanie počasia
- Ekvivalentná neurónovej sieti s tisíckami skrytých neurónov[1]
- Zložená z dvoch častí – adresy lokácií a počítadlá
 - Adresy lokácií – malé množstvo oproti počtu klasifikovaných tried
 - Počítadlá majú uložiť binárne reťazce
 - Pre porovnávanie sa používa prah - rádius


SDM



D. Rogers, "Weather Prediction Using Genetic Memory," *National Aeronautics and Space Administration, Research Institute for Advanced Computer Science technical report*, p. 18, 1990.

SDM


- Pracuje s Hammingovskými vzdialenosťami
- Predpokladáme, že prvky tried sú si v Hammingovskom priestore blízke
- Červené – lokácie
- Čierne - triedy



GENETICKÁ PAMÄŤ

- Problém SDM – vhodné určenie lokácií pamäte
- Riešenie – využitie genetických algoritmov
 - Lokácie sa určia náhodne
 - Do pamäte sa uložia tréningové dáta
 - Určia sa najlepšie lokácie
 - Určia sa najhoršie lokácie
 - Zlé sa vyhodia a nahradia
 - Postup sa opakuje

GENETICKÁ PAMÄŤ



	Address	Fitness
Location A	0110110101	209
Location B	0001001111	52
Location C	1110100100	221
...		482



Selection for
removal

PROBLÉMY PÔVODNEJ GENETICKEJ PAMÄTE

- Autori genetickej pamäti opísanej v pôvodnom článku ako jeden spôsob výberu adries vhodných pre kríženie navrhovali absolútny výber najlepších
- Už pri začiatočných experimentoch sa ukázalo, že to nie je vhodný spôsob výberu, vhodnejší je náhodný výber so zväčšenou pravdepodobnosťou výberu lepšej adresy

PROBLÉMY PÔVODNEJ GENETICKEJ PAMÄTE


- Genetická pamäť opísaná v pôvodnom článku využívala z genetických algoritmov len kríženie – crossover
- To nemôže zaručiť nájdenie optimálneho riešenia

Desired location address:	11010011100011010
1.st best address:	11010000000011010
2.nd best address:	11010000000010010


VYUŽITIE

- Genetická pamäť je schopná rozpoznať väčšie množstvo dát pri zachovaní malého rozsahu
- Výstupom je bitový reťazec vytvorený z počítadiel
- Pre klasifikáciu do tried nie je potrebný bitový reťazec, ale trieda
- Kombináciou tých istých lokácií v pamäti dostaneme pri rozpoznávaní vždy rovnaký reťazec- tj. tú istú triedu
- Môžeme vynechať časť s počítadlami a nahradiť ju napríklad binárnym stromom

GENETIC MEMORY -ÚPRAVY



		
Location A	0	
Location B	1	
Location C	1	



VÝSKUMNÉ CIELE

- Nová metóda klasifikácie vizuálnych slov pre použitie na rozpoznanie objektov v reálnom prostredí
 - Klasifikácia uspôsobená pre binárne deskriptory
 - Možné rozpoznávanie veľkého množstva tried v reálnom čase
- Vylepšenie SDM
 - Úpravy pre použitie s vizuálnymi slovami
 - Úpravy pre zlepšenie použiteľnosti

PREDBEŽNÉ EXPERIMENTY

- Vytvorenie vizuálnych slov z datasetu Caltech 101
- Vytvorenie implementácie SDM
- Implementácia genetického algoritmu
- Implementácia binárneho stromu
- Experimenty na náhodne generovaných dátach
- Vytvorenie slovníkov vizuálnych slov
- Experimenty s klastrovaním v Hammingovskom priestore

VÝSLEDKY TRÉNOVANIA SDM

- 1000 vizuálnych slov, 100 lokácií

