

NEURAL NETWORK BASED EDGE DETECTION

Miloš Janda

Master Degree Programme (2), FIT BUT
E-mail: xjanda16@stud.fit.vutbr.cz

Supervised by: Miroslav Švub
E-mail: svub@fit.vutbr.cz

ABSTRACT

Aim of this article is description of neural network based edge detection methods that are substitute for classic methods of detection using edge operators. The objective of the main part is to show process of generating synthetic images, extracting training datasets and discussing variants of suitable topologies of neural networks for purpose of edge detection.

1. ÚVOD

Detekce hran z hlediska počítačové grafiky, přesněji zpracování obrazu, se zaměřuje na metody určující významné body v digitálním obraze, kde se výrazně mění jas obrazu. Pokud se úplně oprostíme od počítačů a informatiky, tak detekce (zjišťování polohy hran) je pro člověka přirozenou činností. Slouží při vnímání obrazu k rozpoznávání jednotlivých objektů, které tyto hrany opticky oddělují. V oblasti počítačového vidění slouží detekce hran především k segmentaci obrazu a rozpoznávání objektů.

2. DETEKCE HRAN V OBRAZE

Detekci hran, jako proces, lze rozdělit do tří základních fází, kterými jsou fáze filtrování, diferenciacce a detekce. [1] V první fázi je potlačen šum a další chyby vzniklé vzorkováním a kvantováním obrazu. Hlavní fází je zvýraznění hran, tedy oblastí, kde je výrazná změna intenzity jasu obrazu. Poslední fází je pak ztenčení hran a prahování, tedy potlačení nemaximálních hodnot a lokalizace nejvýraznějších bodů (hran).

2.1. KLASICKÝ PŘÍSTUP K DETEKCI HRAN

Klasický přístup k detekci hran je založen na dvou skupinách metod. Velikost změny funkce jasu lze matematicky vyjádřit derivací funkce, kdy největší změna a tudíž i hrana se nacházejí v místech lokálního maxima derivace. První skupinou jsou metody detekce hran založené na aproximaci první derivace funkce jasu. V praxi je nejčastěji používaný Cannyho hranový detektor, Sobelův a Prewittové operátor.


Druhou skupinou jsou metody aproximující druhou derivaci. U první derivace je nutné lokalizovat lokální maxima, u druhé derivace průchody nulou. Mezi hlavní zástupce patří Laplacián, Laplacián Gaussiánu (LoG filtr) a Diferenciál Gaussiánu (DoG filtr), označován jako detektor Marr-Hildreth.

3. DETEKCE HRAN POMOCÍ NEURONOVÉ SÍTĚ

Detekci hran pomocí neuronové sítě, lze opět rozdělit na několik fází. Těmi jsou vytvoření trénovací množiny, extrakce dat pro trénování, samotné natrénování sítě a detekce hran pomocí natrénované sítě. [2] Pro více informací o neuronových sítích doporučuji knihu Machine Learning od Toma Mitchella, případně uvedenou literaturu (2).

3.1. VYTVOŘENÍ TRÉNOVACÍ MNOŽINY

Vytvoření kvalitní trénovací množiny je základním předpokladem k natrénování sítě s vysokou úspěšností detekce hran. V praxi je trénovací množina obrazů tvořena z obrazů syntetických a reálných. Zde se však zaměřuji především na vytvoření trénovací množiny syntetických obrazů za pomoci textur. Nutností je vybrat vhodné textury, kde nejsou zřetelné hrany. Hrany musí být viditelné pouze na hranách polygonů, vyplněných těmito texturami. Jedna textura je použita vždy jako pozadí, další jako výplně základních tvarů.



Obrázek 1: Princip vytvoření syntetických obrazů pro výběr trénovacích dat

3.2. EXTRAKCE TRÉNOVACÍCH DAT

Z náhodně rozmístěných a otexturovaných polygonů dostáváme syntetické obrazy a taktéž i korespondující masky, obsahující informaci o poloze jednotlivých hran. Z těchto vygenerovaných obrazů jsou dále (opět náhodně) extrahovány hranové a nehranové body (na obrázku 2 označeny červenými, resp. žlutými body). Samotná trénovací data pak tvoří intenzity pixelů v daném okolí bodu a očekávaný výstup. Velikost okolí ovlivňuje topologii sítě, jelikož udává počet vstupů neuronové sítě.

3.3. TOPOLOGIE A TRÉNOVÁNÍ NEURONOVÉ SÍTĚ

Topologie sítě je třívrstvá – vstupní vrstva 9 příp. 25 neuronů (okolí 3x3, příp. 5x5), skrytá vrstva obsahující 10-30 neuronů a výstupní vrstva 1 neuron (možno i více, záleží na použité metodě). Trénování sítě je založeno na algoritmu zpětného šíření chyby (Back-propagation) a zvolená aktivační funkce je sigmoida (příp. symetrická sigmoida).


3.4. VARIANTY NEURONOVÝCH SÍTÍ

V této části jsou uvedeny dvě hlavní metody detekce hran pomocí neuronové sítě. Metoda bez klasifikace směru hrany a s klasifikací směru hrany. Výsledky první varianty jsou uvedeny v další kapitole a druhá varianta je předmětem dalšího zkoumání.

- Základní model tvoří, jak bylo uvedeno, neuronová síť s jedním výstupem udávající zda je bod hranový či nehranový. Směr hrany v této metodě nehraje žádnou roli.
- Neuronová síť s více výstupy, udávající nejen sílu hrany, ale i směr hrany. Směr hrany lze udávat ve 4 resp. 8 směrech. Neuronová síť má v tomto případě celkem 5 resp. 9 výstupů, odpovídající síle hrany a jednotlivým směrům.

4. VÝSLEDKY

Uvedené obrázky a hodnoty jsou výsledky modelu neuronové sítě s jedním výstupem. Vygenerováno bylo 10 obrazů, z každého bylo extrahováno 25 okolí bodů (12 hranových a 13 nehranových). Velikost okolí byla nastavena na 3x3 px. Neuronová síť byla trénována s počtem 20 neuronů ve skryté vrstvě.



Obrázek 2: Syntetický obraz (vlevo) s korespondující maskou hran



Obrázek 3: (Zleva) Originální obraz, výsledek neuronové sítě a sobelova operátoru

Výsledek neuronové sítě je uveden na obrázku 3 uprostřed. Pro srovnání je uveden i výsledek sobelova operátoru bez ztenčení hran (obr. 3 vpravo). Procentuální úspěšnost (Accuracy) pak při porovnání se sobelovým operátorem dosahuje hranice 90 procent.

5. ZÁVĚR

Prvotní výsledky ukazují, že kvalitní detekci hran lze provádět nejen klasickým přístupem pomocí hranových operátorů, ale lze k ní využít i neuronové sítě. Prezentovaný výsledek je výsledkem sítě natrénované na velmi malé trénovací množině, lze tedy očekávat, že použití větší trénovací množiny povede k dalšímu zkvalitnění výsledků detekce hran.

PODĚKOVÁNÍ

Tato práce vznikla částečně za podpory grantu VUT FIT, FIT-S-10-2 a specifického výzkumu MSM0021630528.

LITERATURA

- [1] Parker, J. R.: Algorithms for Image Processing and Computer Vision, Wiley Computer Publishing 1998, ISBN 0-471-14056-2
- [2] Kulkarni, A. D.: Artificial Neural Networks for Image Understanding, Van Nostrand Reinhold 1995, ISBN 0-442-00921-6