

Detekcia a rozpoznávanie objektov na obraze

Študent: Lucia Hajduková, Školiteľ: Doc. Ing. Zoltán Tomori, CSc.

UPJŠ Košice, Prírodovedecká fakulta

ABSTRAKT

Cieľom práce je vytvoriť program schopný lokalizovať mikroskopické objekty na upravených snímkach z mikroskopu. Problém je riešený pomocou konvolučnej neurónovej siete zvané U-sieť, ktorá deteguje hrany buniek na snímkach.

Kľúčové slová: strojové učenie, neurónové siete, konvolučné siete, U-siete, rozpoznávanie obrazu, TensorFlow, Keras


ABSTRACT

The aim of this bachelor thesis is to produce a program with ability to localize microscopic objects on preprocessed images. The task is solved with the use of convolutional neural network called U-net that detects edges of cells on images.


Key words: machine learning, neural networks, convolutional networks, U-net, computer vision, TensorFlow, Keras

ÚLOHA

Úlohou tejto bakalárskej práce je segmentovať bunky na mikroskopických snímkach. To znamená vytvoriť binárnu masku, v ktorej čierna hodnota reprezentuje prítomnosť hrany bunky a biela hodnota tvorí všetko ostatné vrátane pozadia i vnútra bunky. Takéto vyznačenie buniek je užitočné pre zisťovanie ich počtu a špecifikovanie ich vlastností.



Vstupný obraz (1.)



Výstupný obraz (2.)

DÁTA

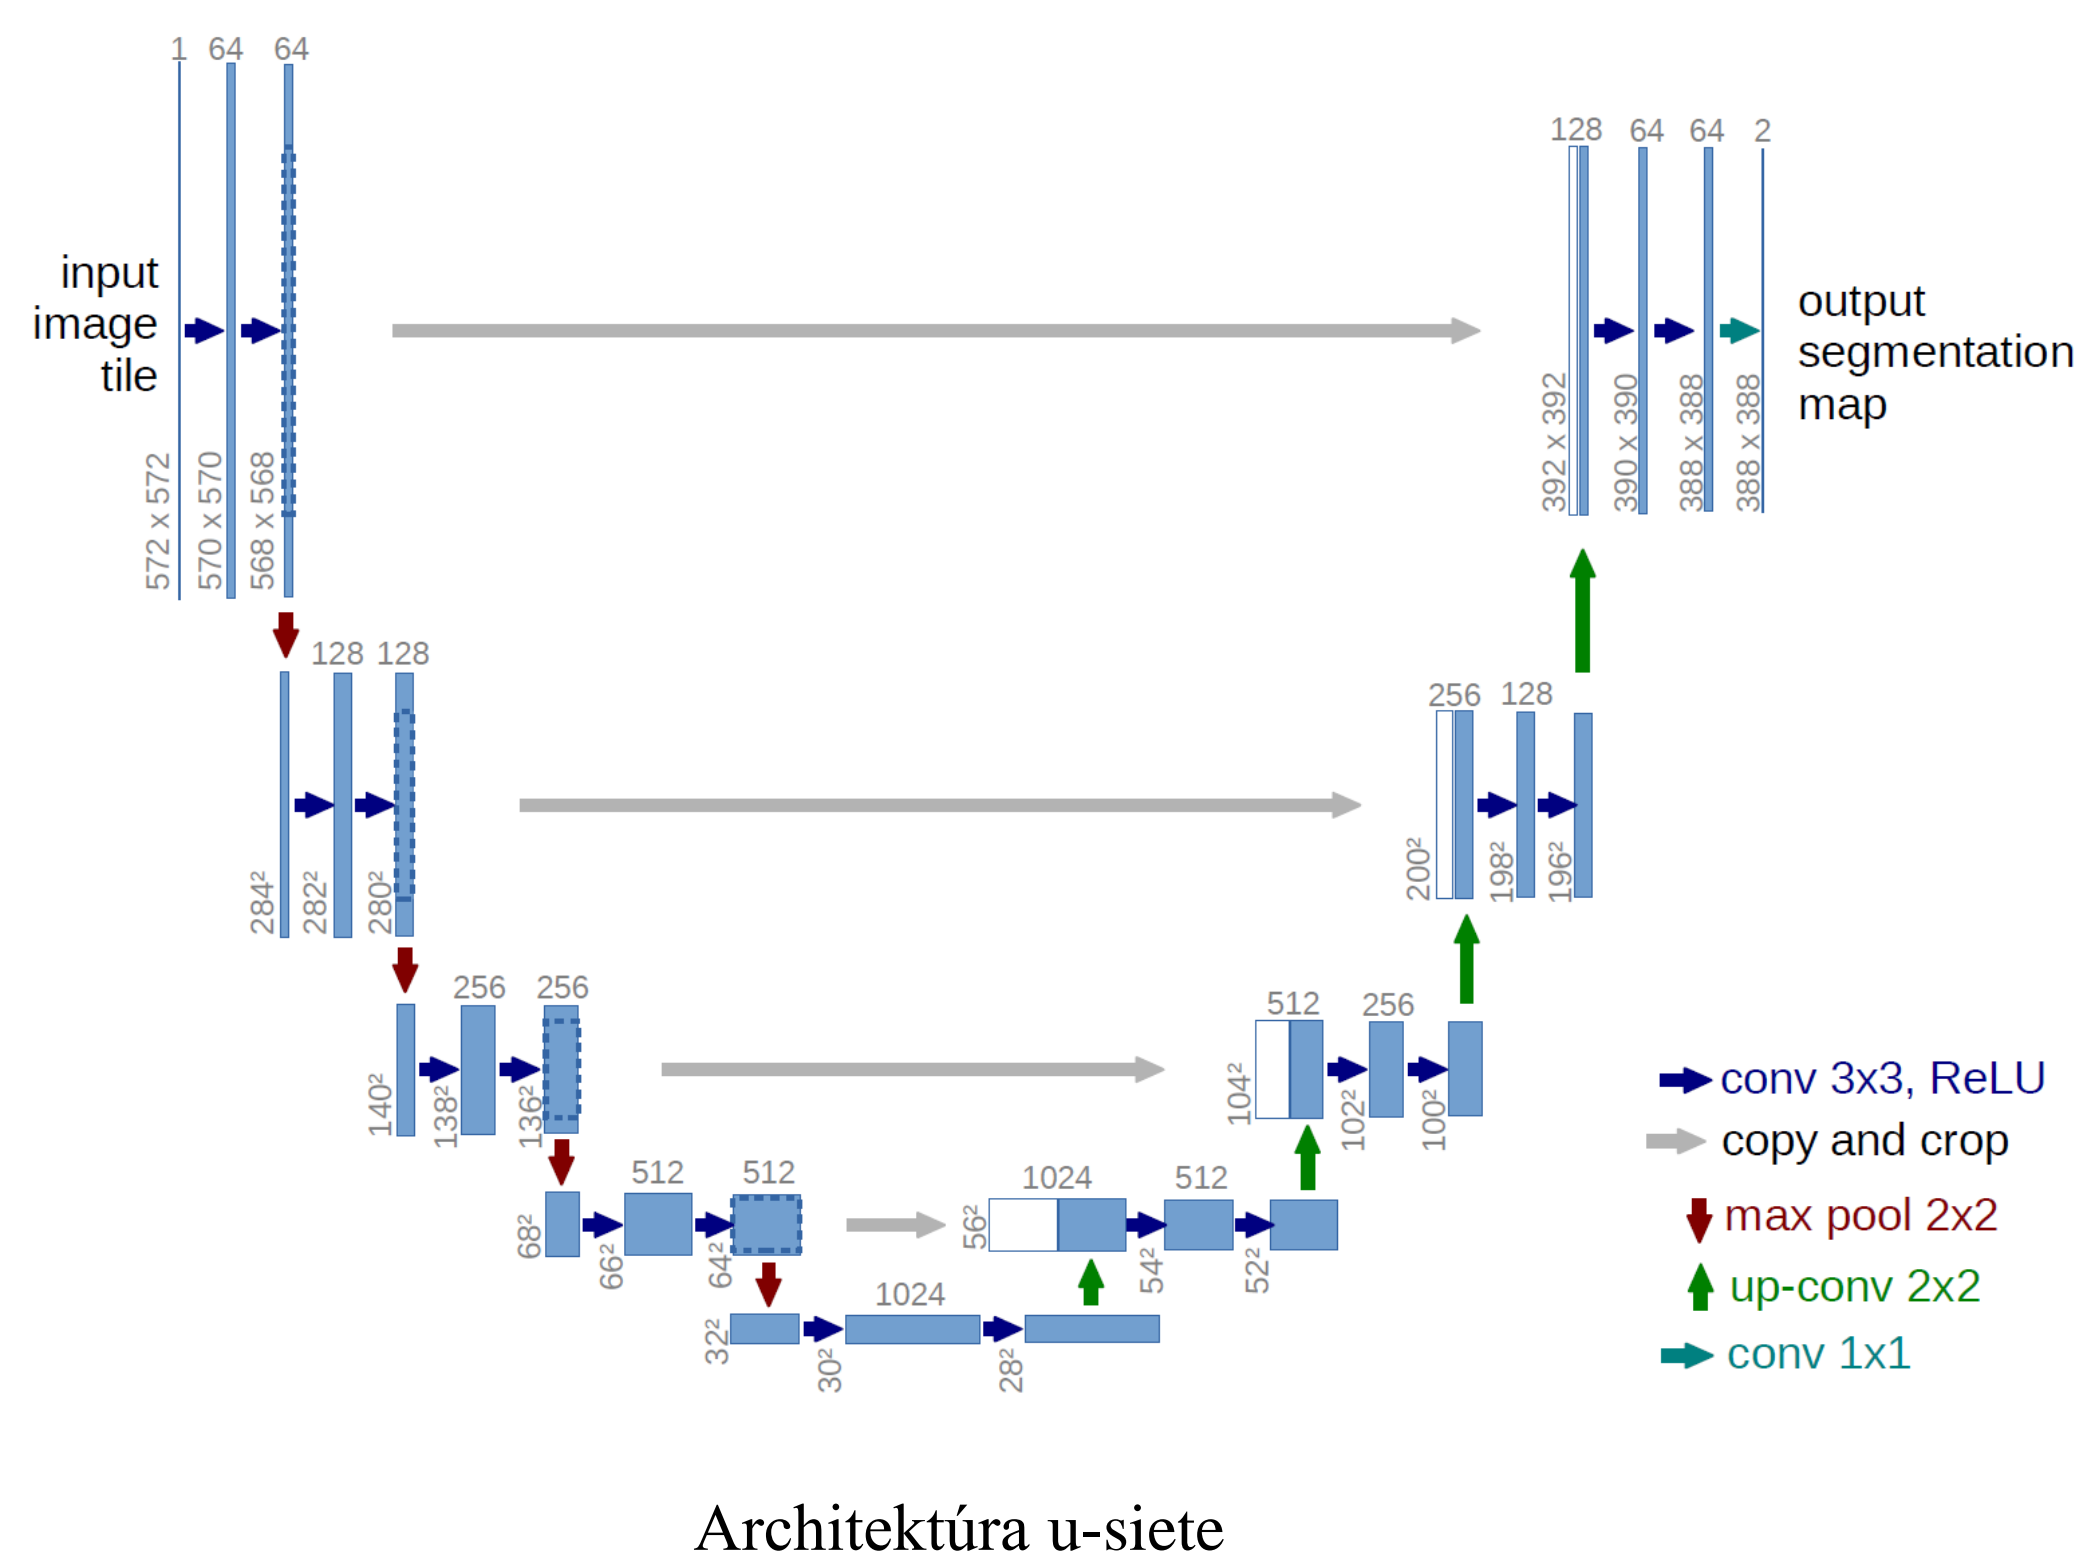
Predspracované mikroskopické snímky na tréningovanie a testovanie modelu boli získané z Neurobiologického ústavu na SAV. Snímky sme podľa štandardného postupu pri tréningovaní neurónových sietí rozdelili do 3 skupín.

1. Tréningová množina vstupných obrázkov
2. Tréningová množina vzorových výstupných obrázkov
3. Testovacia množina vstupných obrázkov, pre ktoré budú sieťou získané výstupné obrázky

Vstupy sme previedli na 8 bitové čiernobiely obrázky o rozmeroch 512 x 512 pixelov a výstupy na 32 bitové čiernobiely obrázky o rozmeroch 512 x 512 pixelov.

METÓDY


Na úlohu segmentácie sme zvolili U-sieť, špeciálny typ konvolučnej neurónovej siete, ktorá pozostáva z dvoch fáz: skracovanie a rozpínanie. Architektúra u-siete je v tvare písmena U, pričom ľavá časť U znázorňuje fázu skracovania a pravá fázu rozpínania.



Architektúra u-siete

U-sieť vo fáze **skracovania** postupuje ako klasická konvolučná sieť. Model je rozdelený do blokov skracovania, ktoré sa niekoľko-krát opakujú. Každý z nich je zložený z dvoch vrstiev vykonávajúcich konvólciiu s jadrom 3x3 s aktivačnou funkciou ReLU a jednej vrstvy zhromažďovania 2x2. Počet máp črt sa v každom bloku zdvojnásobuje, aby sa sieť efektívne naučila komplexné štruktúry. Zhromažďovaním sa redukuje veľkosť vstupu s ponechaním najdôležitejších znakov. Detekcia toho, čo je na obrázku ide na úkor toho, kde sa nájdený objekt nachádza, preto je nutná druhá fáza, ktorá doplní informáciu o lokalizáciu.

Cieľom **fázy rozpínania** je doplniť výstup o pixely zredukované v prvej časti. Postup je symetrický s fázou skracovania s tým rozdielom, že v každom kroku je miesto konvólcie 3x3 aplikovaná opačná konvólcia 2x2, ktorá dvojnásobne zmenšuje počet máp črt a zhromažďovanie je nahradené nadzorkovaním. Týmto dvoma operáciami je v každom bloku získaný predbežný výstup, ktorý je ešte potrebné kombinovať s mapou črt z prvej fázy na tej istej úrovni U. Vďaka tomu sú zachované dôležité črty pôvodného obrázka. Na záver každého bloku je ešte dvakrát vykonaná konvólcia 3x3 s ReLU.



Originálny obraz

Otočenie o 30°

Posunutie o 1/2

Rozšírenie dát

Tréningovanie neurónovej siete si často vyžaduje obrovské množstvo dát, čo môže byť prekážkou. Využili sme skutočnosť, že všetky snímky daných pozorovaných buniek sú si veľmi podobné, a preto stačí na jeden obrázok aplikovať rôzne variácie deformácií, a tým získať niekoľko násobne viac dát. Hovoríme tomu rozšírenie dát. Deformácie, ktoré sme použili boli posunutie, zrkadlenie, priblíženie a otočenie.

NÁSTROJE


Na základe úvodného prieskumu sme si vybrali pre tréningovanie siete programovací jazyk Python verzie 2.6 s rozhraním TensorFlow vyvinutým pre strojové učenie. Využili sme knižnicu Keras zjednodušujúcu prácu s TensorFlow a poskytujúcu množstvo užitočných tried.

Štruktúra modelu bola uložená vo formáte JSON a nastavenie váh vo formáte .hdf5. Na tréningovanie siete sme využili silu výpočtu s GPU, ktorú voľne poskytuje Google prostredníctvom online editoru Google Colaboratory. Tým bolo tréningovanie výrazne zrýchlené a to nám dalo priestor experimentovať s parametrami modelu. Vytvorili sme aj „notebook“ v Google Colaboratory, podľa ktorého môže ktokoľvek zopakovať kroky, ktoré sme vykonávali.

VÝSLEDKY

Vytvorili sme program, ktorý pre každú snímku buniek, nájde pravdepodobnostnú mapu hrán buniek. Táto mapa je čiernobiely obrázok, o ktorom platí, že čím je väčšia pravdepodobnosť, že pixel je pixelom hrany bunky, tým nižšia je jeho hodnota (0-2¹⁶).

Mapa môže byť následne upravená podľa vhodného prahu (napríklad priemerná hodnota alebo hodnota zodpovedajúca percentuálnemu vyjadreniu istoty), čím vznikne binárny obrázok, čo bolo našou úlohou. Na obrázku môžeme vidieť, že aj bez prahovania je predikcia dosť presná.



Originálny obraz

Predikovaný obraz

EXPERIMENTY

Hoci má model pevne danú štruktúru, veľké množstvo parametrov je možné meniť. Napríklad počet epoch, počet krokov v rámci jednej epochy, počet tréningových vzorov a deformácie, ktoré aplikujeme na obrázky.

Naš najlepší model bol natrénovaný na 52 snímkach s krokom 20 a počtom epoch 100. Jeho presnosť bola 94%.

Počas experimentovania sme vždy ukladali vytvorený model (aj po čiastkovom tréningovaní), aby sme ho uchovali pre prípad ďalšieho použitia. Ukladali sme aj medzivýsledky, aby sme nestratili natrénovaný model v prípade akéhokoľvek výpadku.

VYHODNOTENIE

Implementáciou U-siete sme overili, že je vhodná na segmentáciu obrázkov a výhodou oproti klasickej konvolučnej sieti je, že na tréningovanie nepotrebuje také obrovské množstvo dát. V porovnaní s riešením tej istej úlohy doteraz najpresnejšou metódou spracovania obrazu watershed, sme dosiahli o niečo nižšiu presnosť. Tento nedostatok by sa dal eliminovať ďalšími experimentmi s parametrami u-siete.

Výsledný model je možno jednoducho použiť v aplikáciách v akomkoľvek programovacom prostredí. Môže byť uložený vo formáte .hdf5 alebo v rade ďalších.

REFERENCIE

1. Ronneberger, O. Fischer, P. Brox, T.: U-Net: Convolutional Networks for Biomedical Image Segmentation. Eprint arXiv:1505.04597. (2015) Dostupné na <https://arxiv.org/abs/1505.04597>
2. Michael A. Nielsen, "Neural networks and deep learning!", Determination Press, 2015
3. Keras: The Python Deep Learning Library, <https://keras.io/>
4. Keras and Convolutional Neural Networks (CNNs), <https://www.pyimagesearch.com/2018/04/16/keras-and-convolutional-neural-networks-cnns/>
5. <https://colab.research.google.com/>

KONTAKT

Mail: 5187016@upjs.sk

Web: <https://s.ics.upjs.sk/~lhajdukova/bp/bp.html>

