


# Spracovanie mračien bodov pomocou neurónových sietí

Lukáš Gajdošech, Martin Madaras

Katedra Aplikovanej Informatiky, FMFI UK



# Úvod

- Prvý semester magisterského štúdia, začiatok, rady sú vítané!
- Práca nadväzuje na bakalársku, ktorou bol nástroj na manuálne spracovanie.




# Dáta

- Snímky z PhoXi 3D Scanner (light-structured scanner), rôzny šum.



## Štandard

- Filtrácia klasickým algoritmom, využívajú sa prekryvy medzi skenmi.
- Nevýhoda: potreba veľkého množstva skenov.



- Iné: PassThrough filter, Median filter, K-nearest neighbor mean distance...
- Nevýhody: kladú na šum podmienky, potrebná analýza/vstup používateľa.

## Problém

Vstup: usporiadane mračno bodov v mriežke veľkosti  $w \times h$  (single-view). Vzdialenosť medzi bunkami je daná a o existujúcom bode vieme:

- hĺbku (z súradnica,  $x, y$  sú implicitné)
- intenzitu  $i \in [0, 1]$
- normálu


Výstup: Mračno bodov bez šumu - per point, per region?...

## Dáta

Z jednej snímky vieme získať veľa vstupov, ako výseky posuvného okna. Pretože na trénovanie ich potrebujeme veľké množstvo...


# PointNet: Deep Learning for 3D Classification and Segmentation I

- Priame spracovanie mračna bodov, bez konverzie do voxelov/obrázkov.
- Dôležité vlastnosti: invariantnosť poradia, transformácií, lokálne štruktúry
- Nie je konvolučnou sieťou, jednoduchá architektúra kombinujúca viacero MLP.
- Táto siet' pracuje s neusporiadaným mračnom - dôraz na invariantnosť od vstupnej permutácie bodov pomocou max poolingu.




## PointNet: Deep Learning for 3D Classification and Segmentation II

- Myšlienka je aproximovať funkciu  $f : \{\{x_1, \dots, x_n\} \mid x_i \in \mathbb{R}^m\} \rightarrow \mathbb{R}$ ;  $f(\{x_1, \dots, x_n\})$  pomocou  $g : \mathbb{R}^{k^n} \rightarrow \mathbb{R}$ ,  $h : \mathbb{R}^m \rightarrow \mathbb{R}^k$ ;  $g(h(x_1), \dots, h(x_n))$
- Vrstvy budujú funkciu  $g$ , pomocou rôznych  $h$  možno aproximovať rôzne  $f$ .




# U-Net: Convolutional Networks for Biomedical Image Segmentation I

- Potreba náučovať sieť bez masívneho objemu trénovacích dát.
- "The architecture consists of a contracting path to capture context and a symmetric expanding path that enables precise localization."
- Spomenutý ďalší od Ciresan et al., kde sieť dostávala výseky obrázka.
- Takýchto výsekov môžeme dostať omnoho viac, ako je trénovacích dát.
- Techniky augmentácie dát.



# U-Net: Convolutional Networks for Biomedical Image Segmentation I



## Rôzne články určené pre obrazové dátá

- Niekoľko sietí, ktoré berú na vstupe mračno prevedené do obrázka.
- "Deep Learning for Image Denoising: A Survey"


Table 1. Comparisons of different methods with  $\sigma = 25$  for image denoising.

Methods	PSNR	Dataset
BM3D [9]	28.57	BSD68
WNNM [14]	28.83	BSD68
TNRD [7]	28.92	BSD68
DnCNN [45]	29.23	BSD68
FFDNet [46]	29.19	BSD68
IRCNN [47]	29.15	BSD68
DDRN [37]	29.18	BSD68

- Peak signal-to-noise ratio:  $PSNR = 10 * \log\left(\frac{MAX_I^2}{MSE_{I,K}}\right)$

## Dáta


- Okolie veľkosti  $n \times n$ ;  $n \in \{13, 15, 17\}$ .
- Máme stredný bod  $c$  a všetky jeho okolité body  $o^i; 0 \leq i \leq n \times n$ ;  $o^i \neq c$
- Pre každý bod  $o^i$  zoberieme  $|c_{depth} - o_{depth}^i|, |c_{intensity} - o_{intensity}^i|, dist(c_{normal}, o_{normal}^i)$
- Máme maticu s  $n \times n - 1$  riadkami a 3 stĺpcami.
- Pre jednoduchosť rozrolujeme do jedného  $(n \times n - 1) \times 3$  vektora.



## Vlastnosti

- Bol výber vlastností/features (rozdiel' hĺbky, normály a intenzity) správny?
- Predpoklad, že rozdiel' týchto hodnôt je dôležitý pri rozlišovaní šumu.
- Považujem to za vhodný *feature extraction*, zjednodušenie problému pre siet'.
- Veľkosť okolia som menil, ako aj samotné vlastnosti.
- Napríklad pre zoznam  $\{o_{depth}^i, o_{normal}^i, o_{intensity}^i \mid o^i; 0 \leq i \leq n \times n; o^i \neq c\}$  nenašla siet' nič rozumné - neporozumela významu rozdielov?
- Navrhnuté riešenie zabezpečuje invariantnosť od transformácií.



# Siet'



- Schválne jednoduchý (MLP) model s jednou (dvoma) skrytými plne prepojenými vrstvami.
- $k \in [16, 32]$ , GDC, optimizer = Adam, learning rate = 0.001, activation function = RELU
- Na výstupe binárny klasifikátor (zaokrúhlenie).
- Natrénované na výsekok dát jedného typu objektov (glazúrovaná keramika).



# Výsledky I

- Viditeľný rozdiel v normálach.





## Výsledky II

- Problém s väčšími zhlukmi - stredný bod má homogénne okolie.



## Výsledky III

- Osamotená časť geometrie na skene vyhodnotená ako šum.



# Problémy

- Berieme do úvahy iba obmedzený kontext, v závislosti od hodnoty  $n$
- Riešenie nemusí byť invariantné k poradiu bodov.
- Veľmi pomalé - MLP musí byť spustený na každom výseku (bode) zvlášť.
- ...

# Literatúra I

-  R. Charles, Hao Su, Mo Kaichun, and Leonidas Guibas.  
PointNet: deep learning on point sets for 3D classification and segmentation.  
In *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 77–85, 07. 2017.
-  Aurlien Gron.  
Hands-on machine learning with scikit-learn and tensorflow, 2017.
-  Chen Liu, Kihwan Kim, Jinwei Gu, Yasutaka Furukawa, and Jan Kautz.  
PlaneRCNN: 3d plane detection and reconstruction from a single image, 12. 2018.
-  Olaf Ronneberger, Philipp Fischer, and Thomas Brox.  
U-Net: convolutional networks for biomedical image segmentation.  
volume 9351, pages 234–241, 10. 2015.
-  Chunwei Tian, Yong xu, Lunke Fei, and Ke Yan.  
Deep learning for image denoising: A survey, 10. 2018.