Pontfelhő szegmentálás mesterséges intelligencia segítségével

Budapesti Műszaki és Gazdaságtudományi Egyetem
Általános- és Felsőgeodézia Tanszék
Rédey szeminárium

Előadó: Hrutka Bence Péter

2023.11.27.

BUDAPESTI MŰSZAKI
ÉS GAZDASÁGTUDOMÁNYI EGYETEM
Építőmérnöki Kar - építőmérnöki képzés 1782 óta
Általános és Felsőgeodézia Tanszék

TARTALOM

- Bevezetés
- AI, ML és DL
- Pontfelhő jellemzők
- Gépi tanuláson alapuló feldolgozások
- Mélytanulás
- Összegzés

Szegmentálás

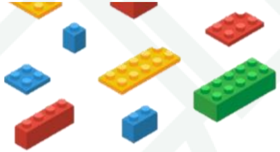

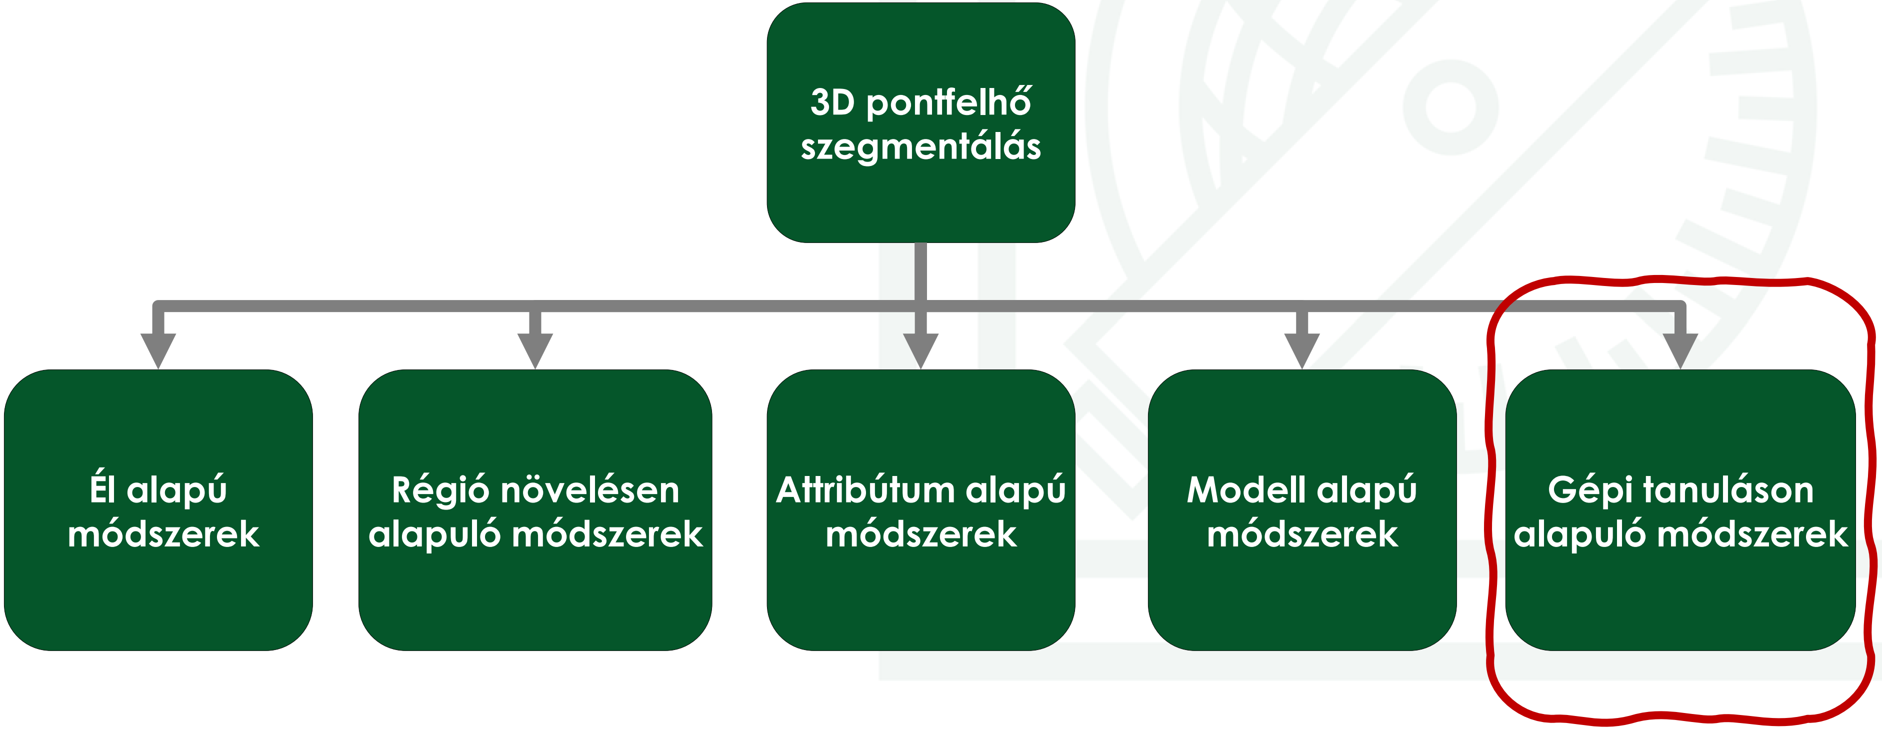

Mesterséges intelligencia

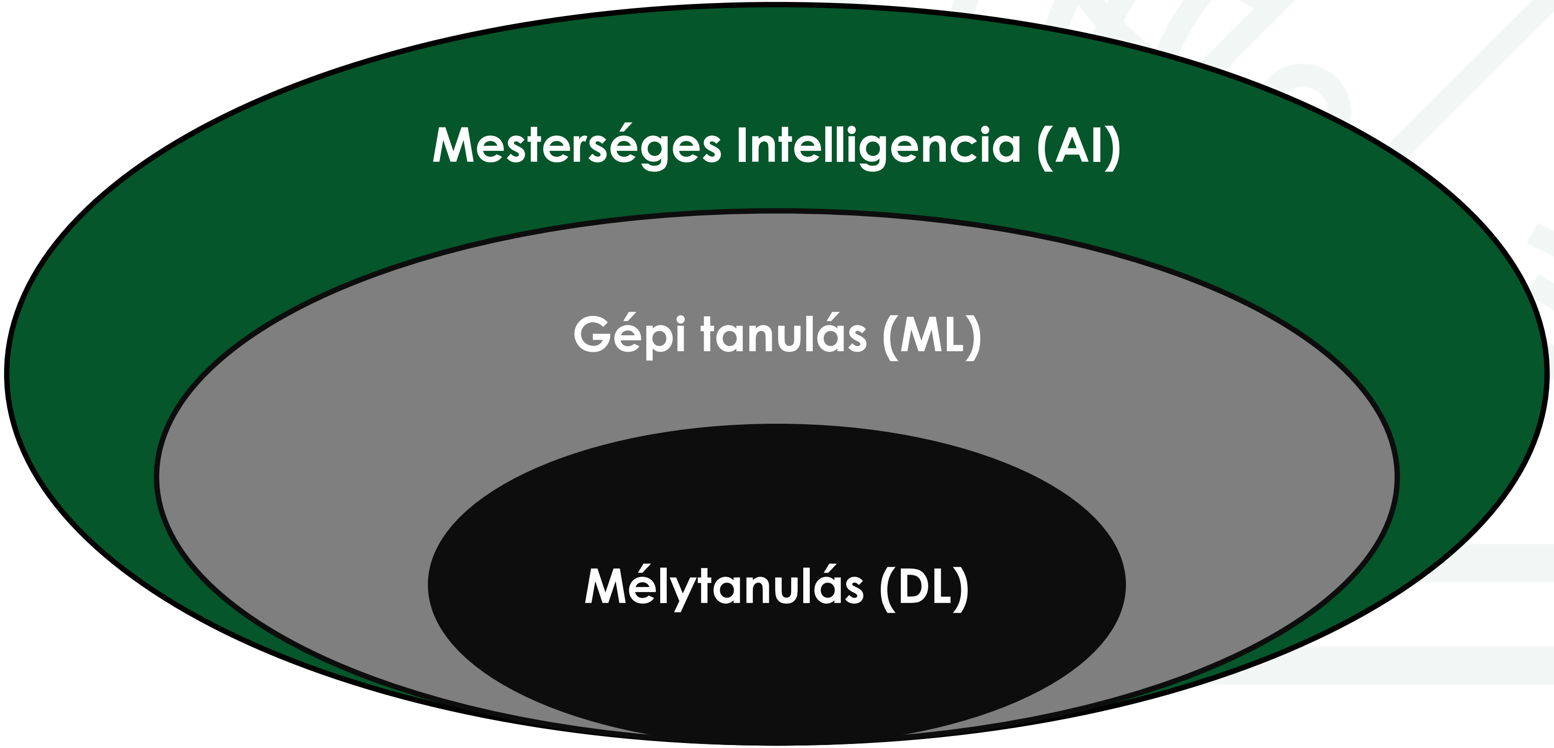

Machine Learning

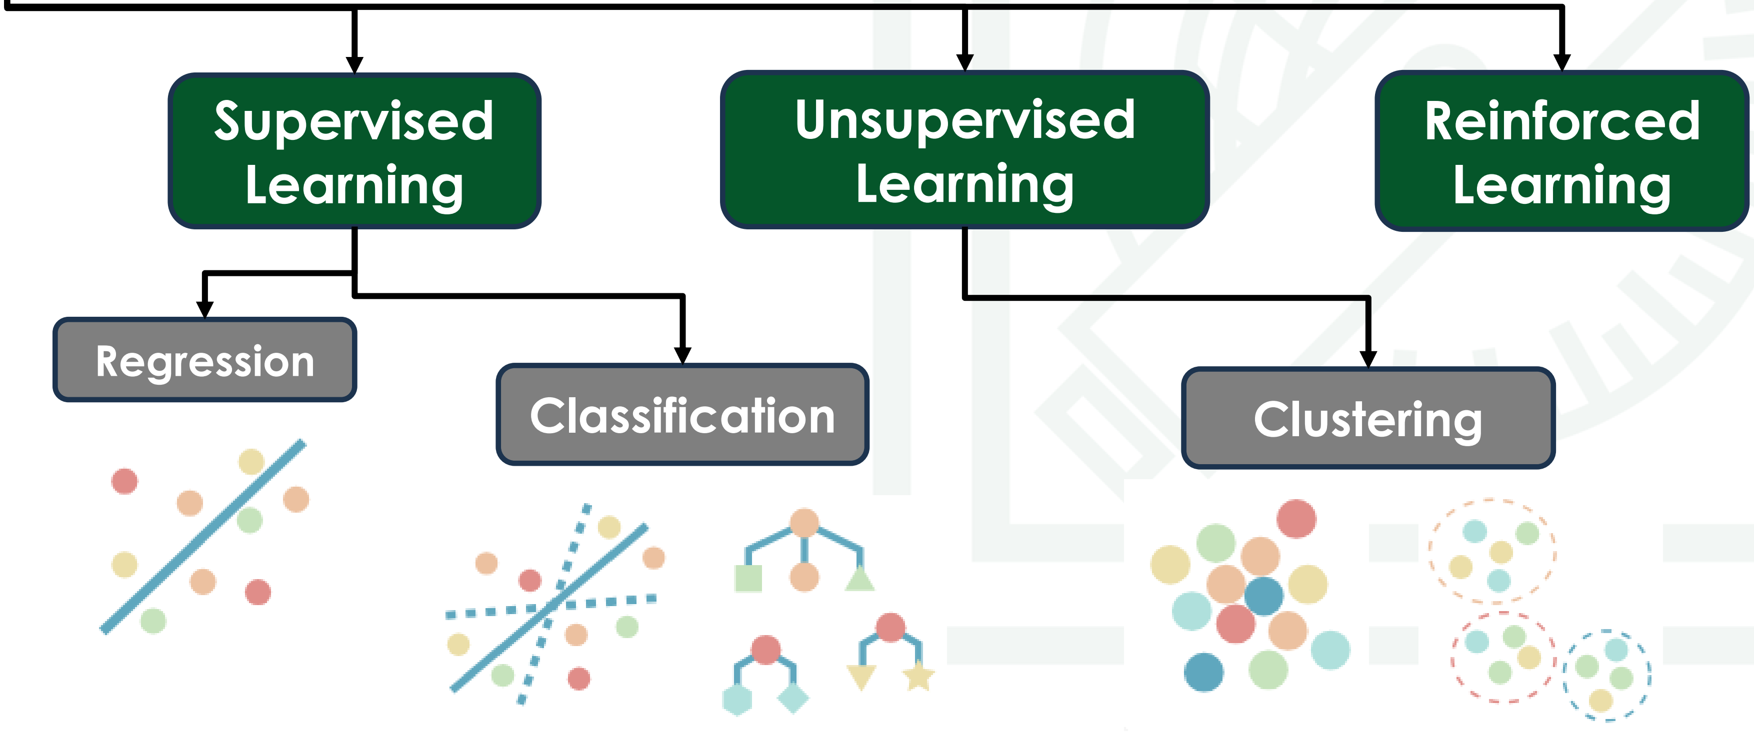

MACHINE LEARNING

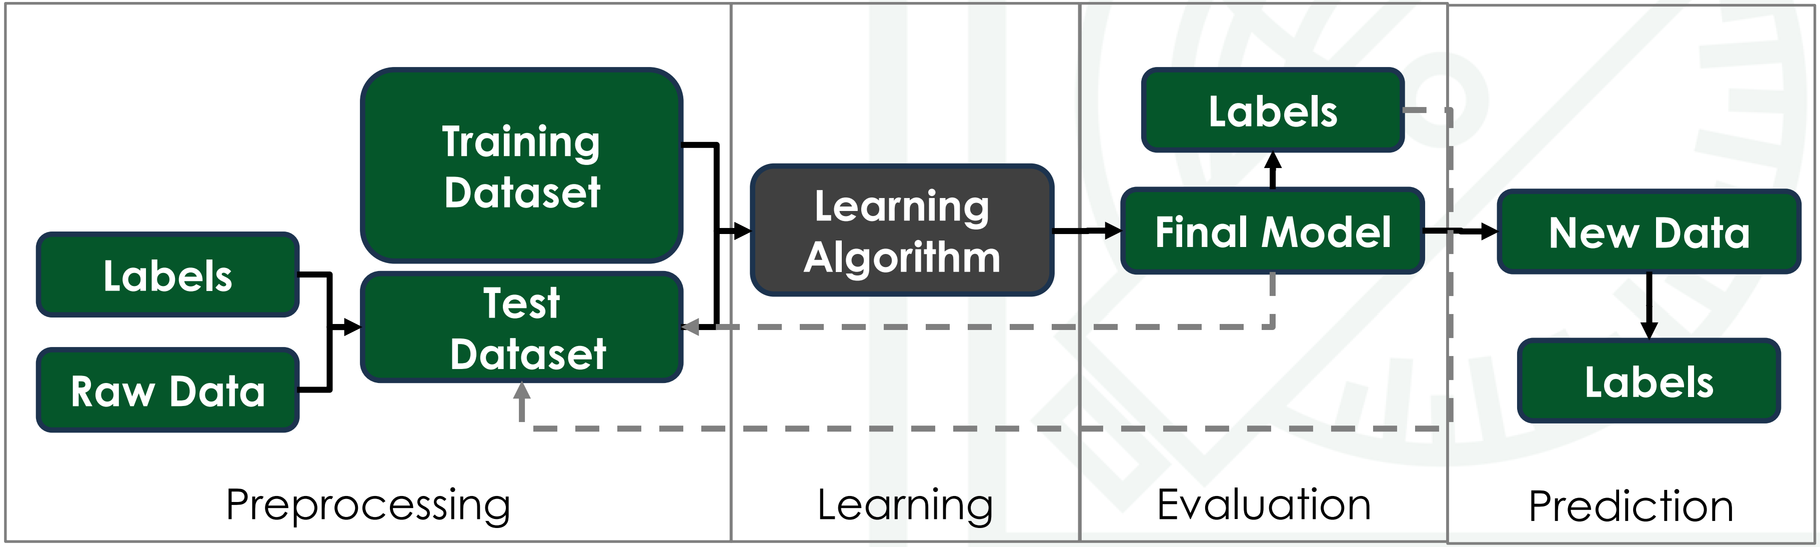

Feature Extraction and Scaling, Sampling

Model Selection, Performance Metrics, Hyperparameter Optimalization

MIT TAKAR AZ AZ ELŐKÉSZÍTÉS?

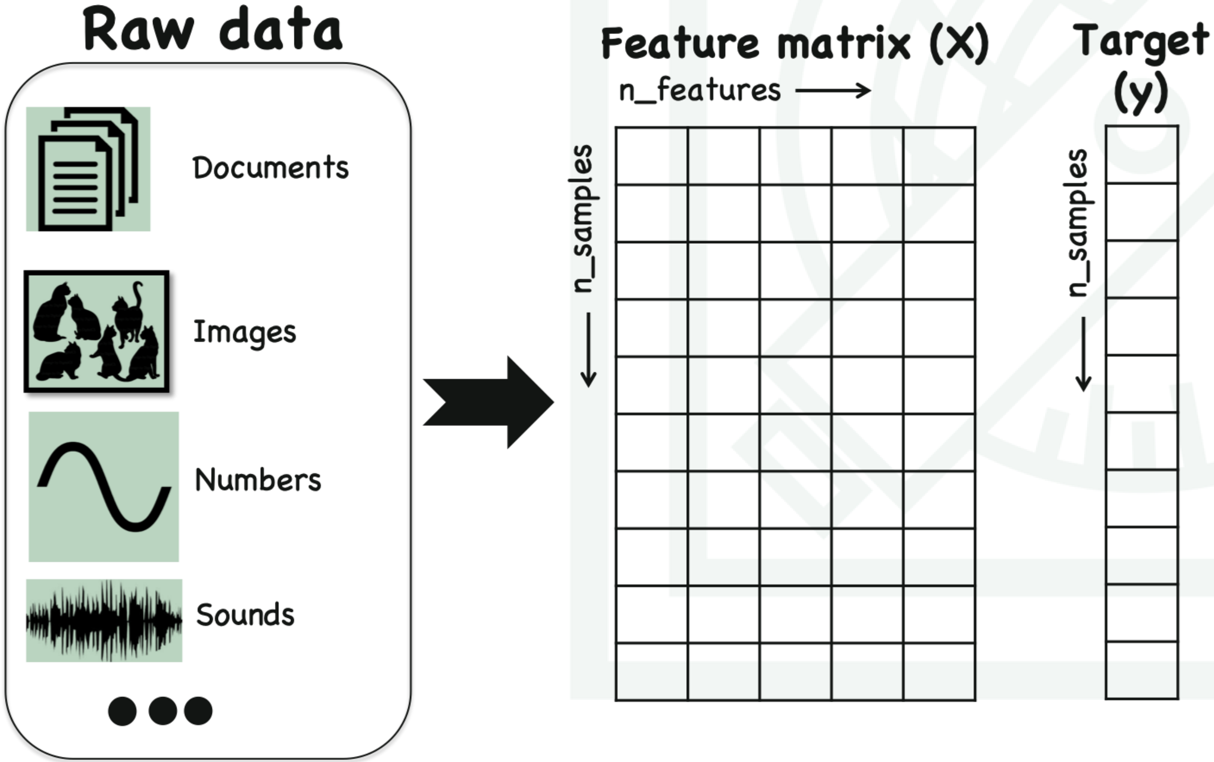

Machine Learning vs. Deep Learning

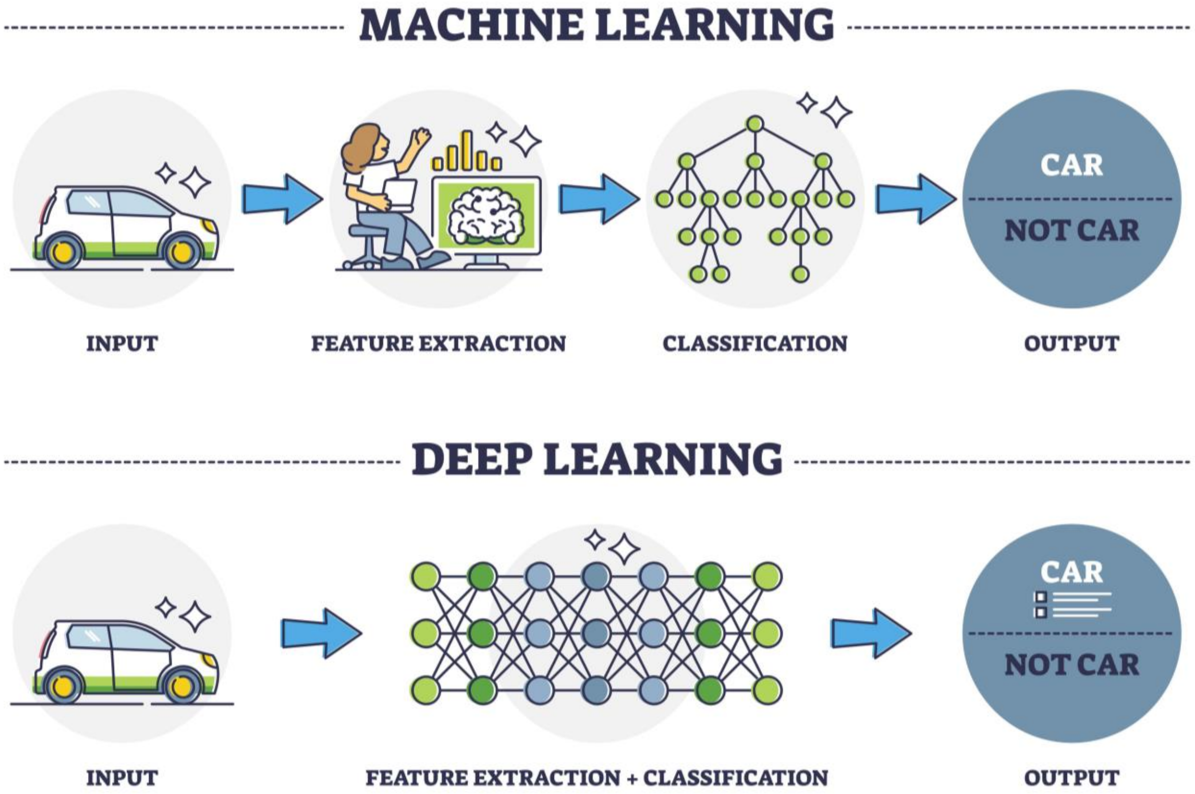

Forrás: https://www.turing.com/kb/ultimate-battle-between-deep-learning-and-machine-learning

Pontfelhő jellemzők

- Geometriai jellemzők
  - *Koordináták*
  - *Pontsűrűség*
  - *Görbület*
- Spektrális jellemzők
  - *RGB*
  - *Intenzitás*
- Sajátértékeken alapuló jellemzők

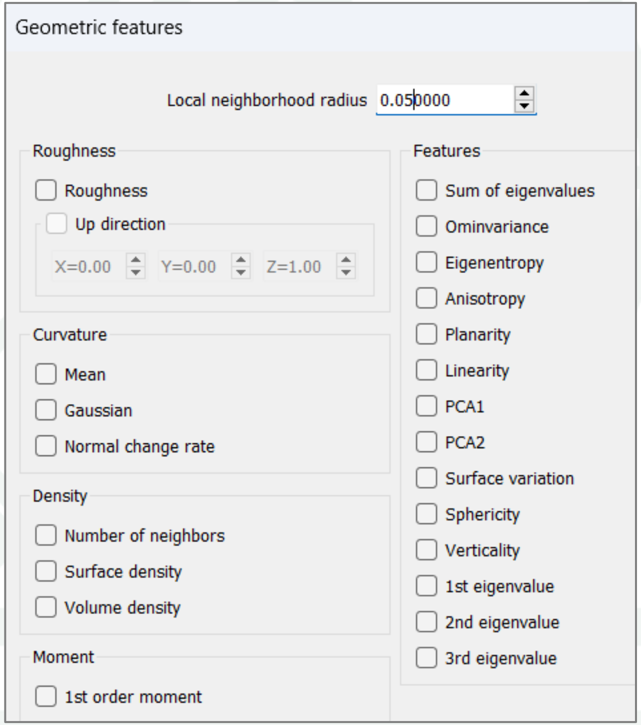

Feng - Guo 2018.

SAJÁTÉRTÉKEKEN ALAPULÓ JELLEMZŐK

- A pont és környezete
  - *„R" sugár*
- Ponthalmazra
  - *Voxel*

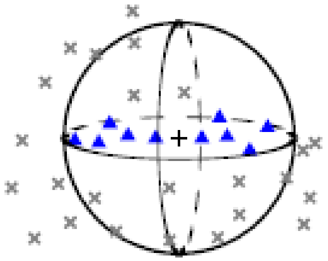

$$\mathbf{A} = \begin{bmatrix} x_1 - \bar{x} & y_1 - \bar{y} & z_1 - z \\ \vdots & \vdots & \vdots \\ x_m - \bar{x} & y_m - \bar{y} & z_m - z \end{bmatrix}$$

Mayr et al. 2017.

Sajátértékeken alapuló jellemzők

- Kovariancia mtx.
  - *Sajátértékek*
  - $\lambda_1 \geq \lambda_2 \geq \lambda_3$

$$\boldsymbol{Q} = \mathbf{A}^{\mathrm{T}}\mathbf{A} = \begin{bmatrix} \sum_{i=1}^{m}(x_i-\bar{x})^2 & \sum_{i=1}^{m}(x_i-\bar{x})(y_i-\bar{y}) & \sum_{i=1}^{m}(x_i-\bar{x})(z_i-\bar{z}) \\ \sum_{i=1}^{m}(x_i-\bar{x})(y_i-\bar{y}) & \sum_{i=1}^{m}(y_i-\bar{y})^2 & \sum_{i=1}^{m}(y_i-\bar{y})(z_i-\bar{z}) \\ \sum_{i=1}^{m}(x_i-\bar{x})(z_i-\bar{z}) & \sum_{i=1}^{m}(y_i-\bar{y})(z_i-\bar{z}) & \sum_{i=1}^{m}(z_i-\bar{z})^2 \end{bmatrix}$$

Mayr et al. 2017.

SAJÁTÉRTÉKEKEN ALAPULÓ JELLEMZŐK

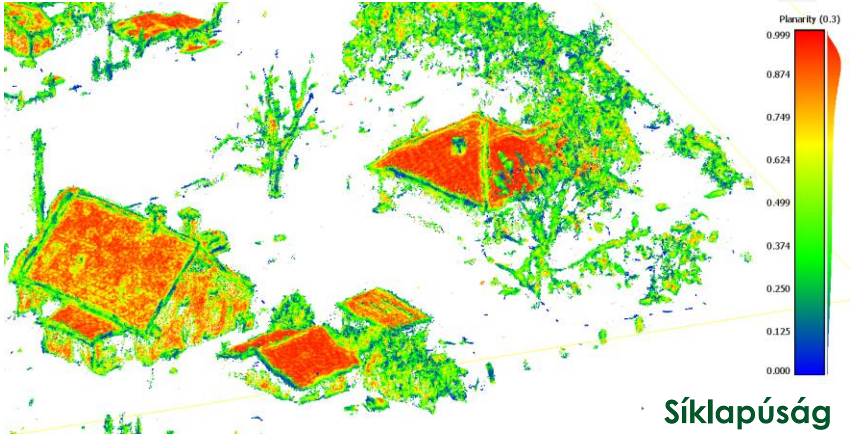

Síklapúság

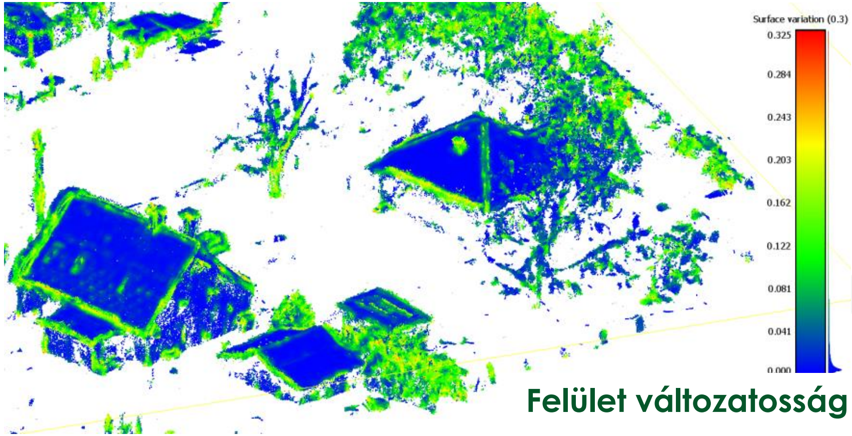

Felület változatosság

Sajátértékeken alapuló jellemzők	Meghatározás
Omnivariancia (omnivariance)	$\sqrt[3]{\lambda_1 \cdot \lambda_2 \cdot \lambda_3}$
Anizotrópia (anisotropy)	$\frac{(\lambda_1 - \lambda_3)}{\lambda_1}$
Síklapúság (planarity)	$\frac{(\lambda_2 - \lambda_3)}{\lambda_1}$
Felület változatosság (surface variation)	$\frac{\lambda_3}{(\lambda_1 + \lambda_2 + \lambda_3)}$
Gömbszerűség (sphericity)	$\frac{\lambda_3}{\lambda_1}$

FELÜGYELT GÉPI TANULÁS

Kiindulás

- Korábbi szegmentálás
- Tető vagy növényzet?

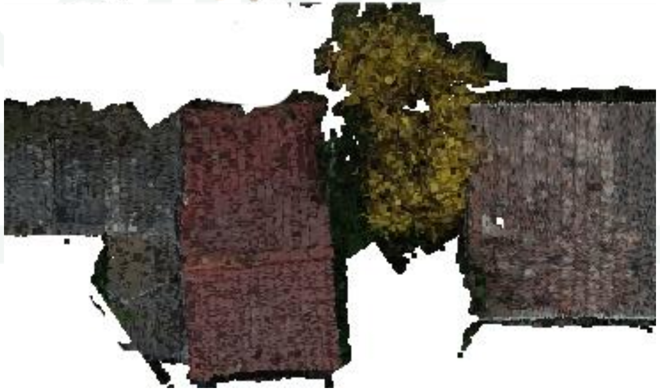

ELŐKÉSZÍTÉS

- Manuális címkézés
  - Tető
    - 1 175 660 db
  - Növényzet
    - 306 057 db

Barnag

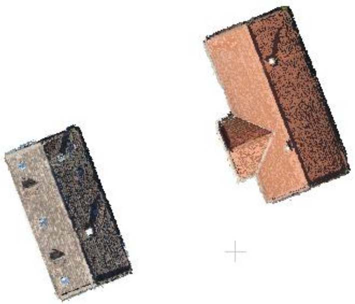

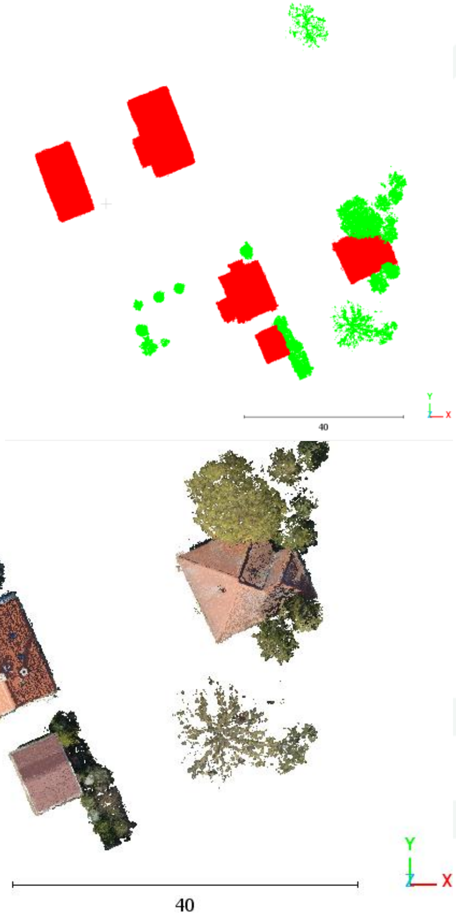

JELLEMZŐK

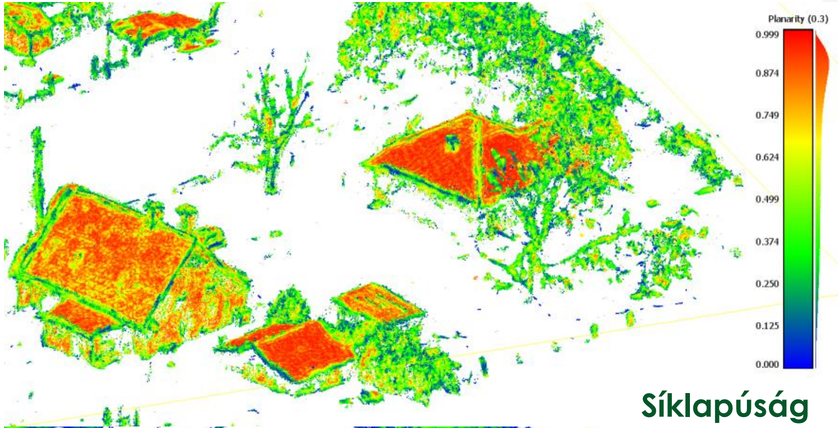

Síklapúság

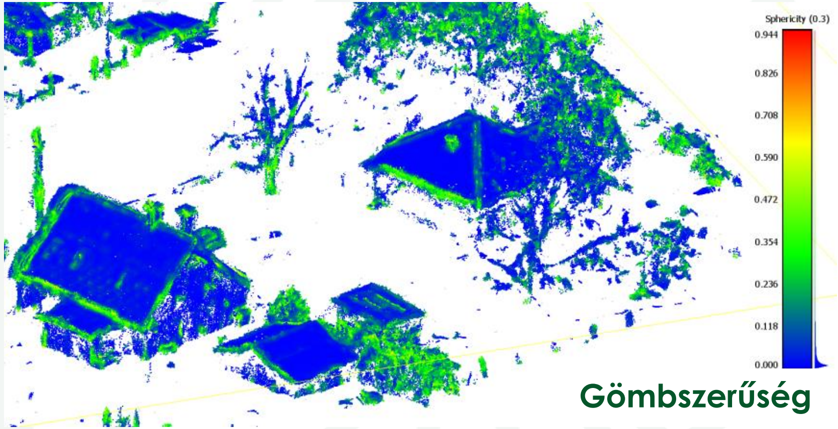

Gömbszerűség

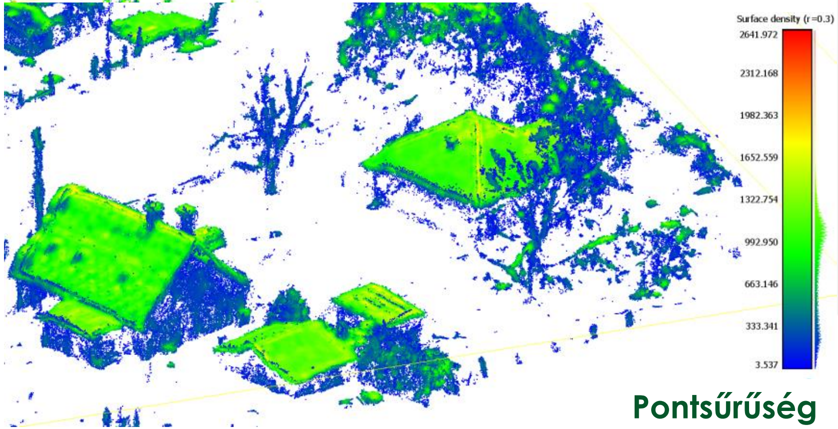

Pontsűrűség

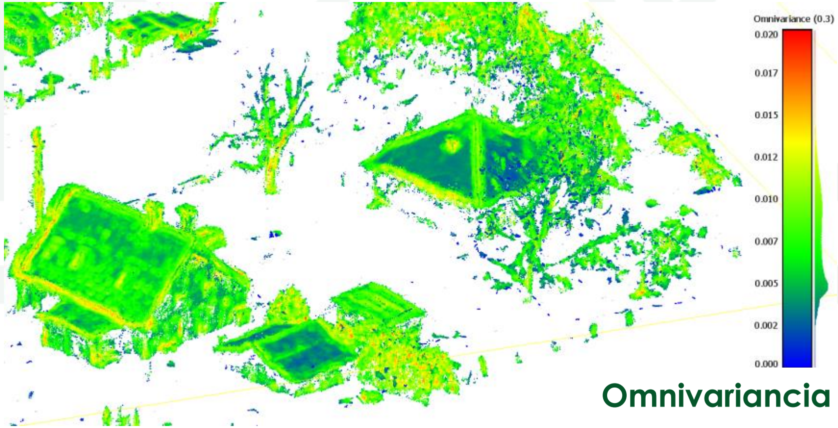

Omnivariancia

VÁLASZTOTT ALGORITMUSOK

- K-Nearest Neighbors
- Random Forest Classifier
- Multi-Layer Perceptron

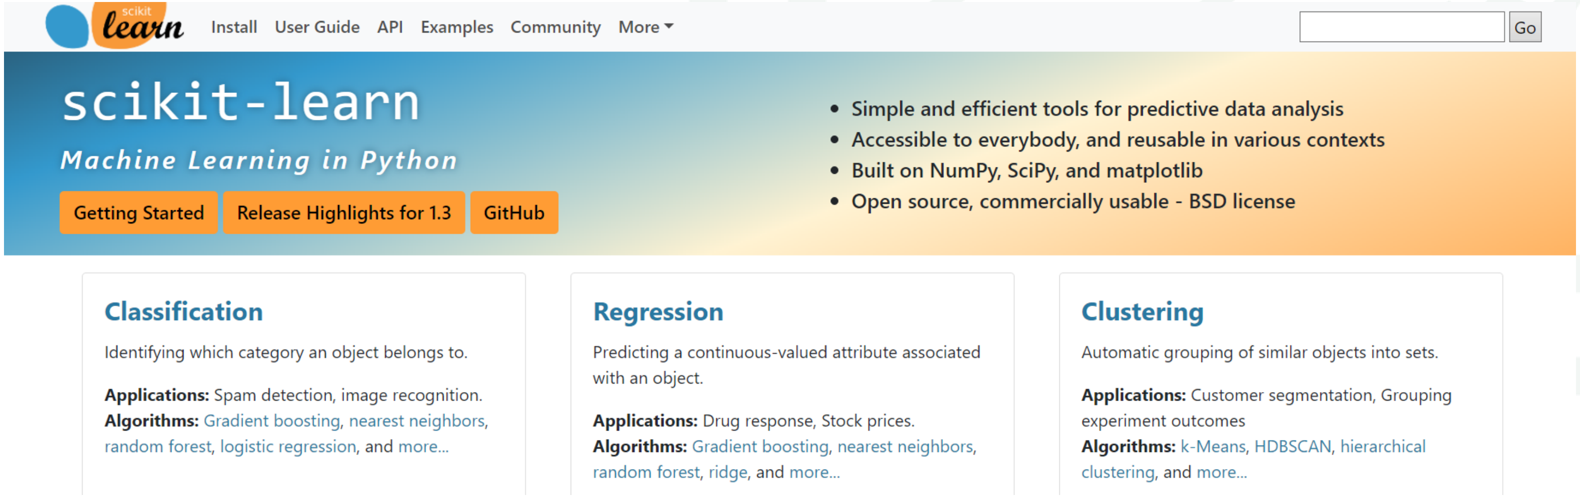

K-Nearest Neighbors - KNN

- Nincs igazi tanítás
- Jellemzők tárolása
- Új pont
- „k” legközelebbi szomszéd
  - *Távolság?*
- Szavazás

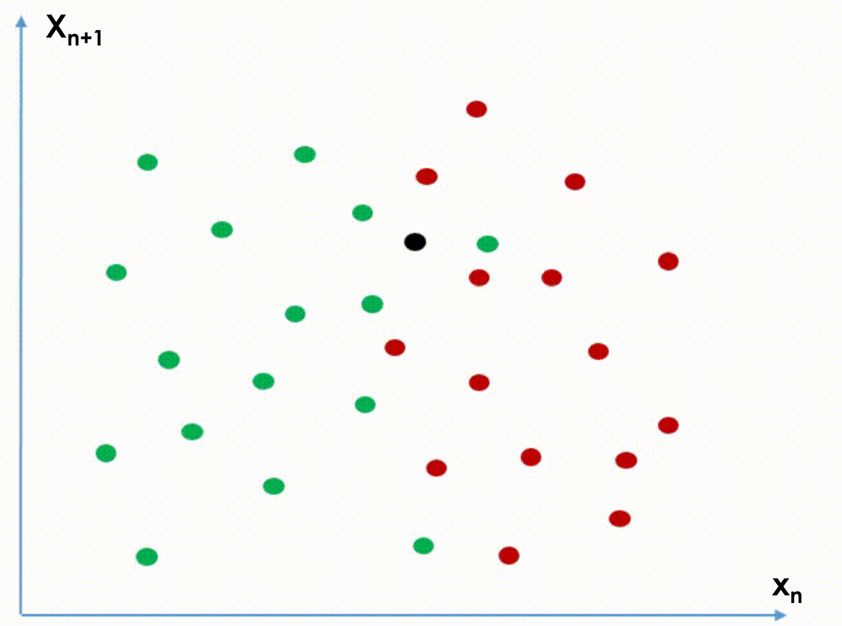

Forrás: https://machinelearningknowledge.ai

Awange et al. 2020; Bonaccorso 2018.

Random Forest Classifier - RFC

- Alapja: döntési fa
- „N” darabot készít
  - *Különböző adatok*
  - *Különböző jellemzők*
- Szavazás

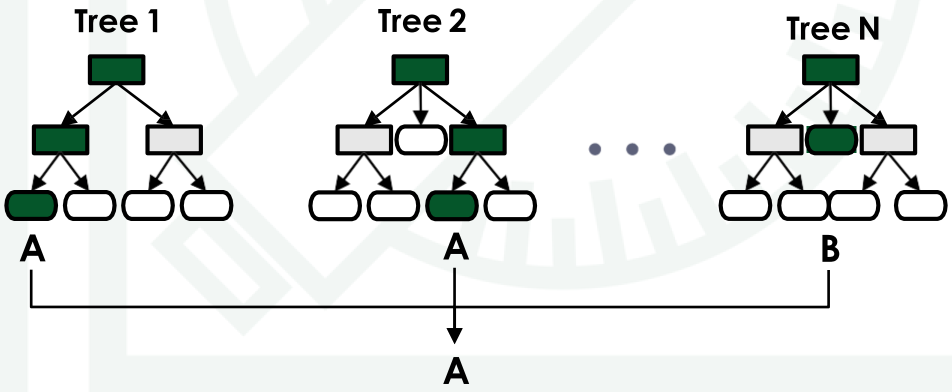

Awange et al. 2020; Bonaccorso 2018.

Multi-Layer Perceptron - MLP

- Alapja: neuron
- Aktivációs függvény (f_a)

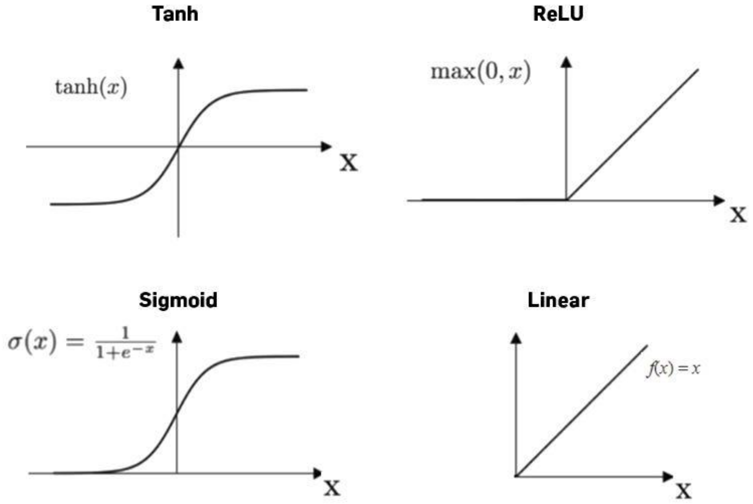

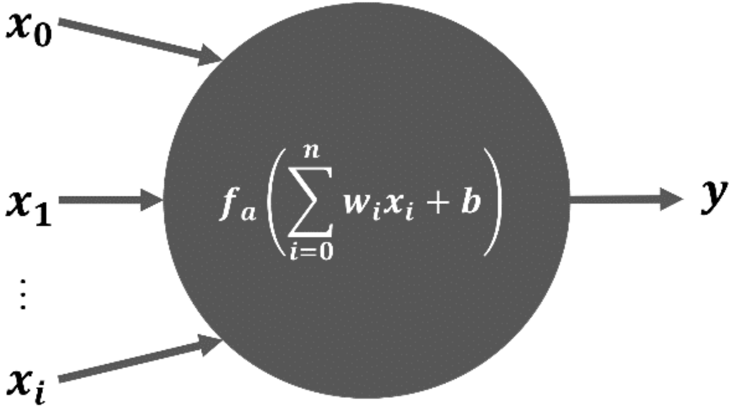

Awange et al. 2020; Bonaccorso 2018.

Multi-Layer Perceptron - MLP

- Több réteg
  - *Bemeneti*
  - *Rejtett*
  - *Kimeneti*
- Tanítás: súlyok, eltolások meghatározása
- Célfüggvény (L) minimalizálás

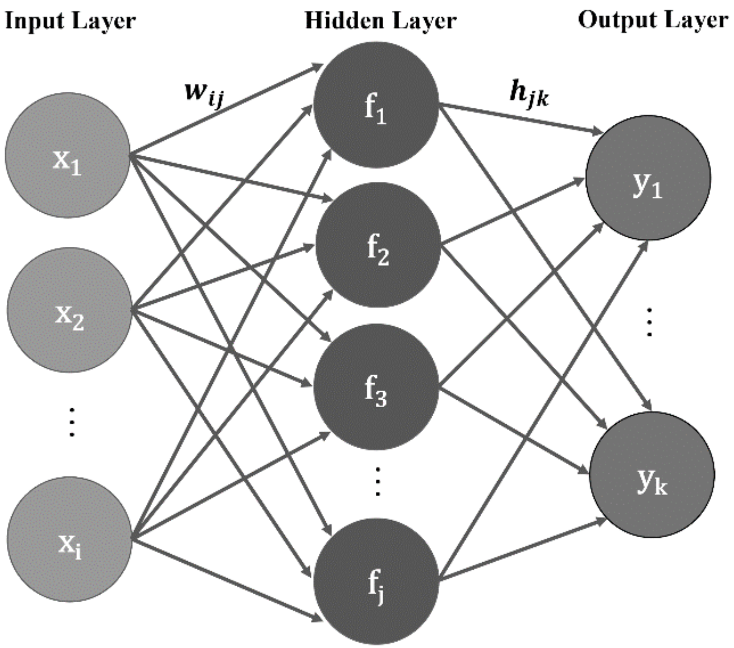

$$L = \frac{1}{n}\sum_{i=1}^{n}\left(y_i^{Predicted} - y_i^{Target}\right)^2$$

Awange et al. 2020; Bonaccorso 2018.

Multi-Layer Perceptron

- Célfüggvény változása az egyes súlyokra
  - *Parciális deriváltak számítása*
  - *Hibavisszaterjesztés (backpropagation)*

$$\frac{\partial L}{\partial w_{ij}} : \frac{\partial L}{\partial h_{jk}}$$

- Tanulás: hálózat súlyainak változása → Véletlen gradiens csökkentés (SGD)
  - *η – tanulási sebesség (learning rate)*

$$\begin{cases} h_{jk}^{(t+1)} = h_{jk}^{(t)} - \eta \frac{\partial L}{\partial h_{jk}} \\ w_{ij}^{(t+1)} = w_{ij}^{(t)} - \eta \frac{\partial L}{\partial w_{ij}} \end{cases}$$

Bonaccorso 2018.

ÖSSZEHASONLÍTÁS

- Accuracy
- Confusion Matrix
  - *True Positive (TP)*
  - *True Negative (TP)*
  - *False Positive (FP)*
  - *False Negative (FN)*
- Recall
- Precision
- F1-score

Awange et al. 2020; Bonaccorso 2018.

$$Accuracy = \frac{N_{correct\ pred.}}{N_{total\ pred.}}$$

True

Predicted

Confusion mtx.	**Positive**	**Negative**
Positive	**TP**	**FP**
Negative	**FN**	**TN**

$$Recall = \frac{TP}{TP+FN}$$

$$Precision = \frac{TP}{TP+FP}$$

$$F1\text{-}score = \frac{2 \cdot Precicsion \cdot Recall}{Precision+Recall}$$

Összehasonlítás

- ~150 MB (.las) adat
  - *Jellemzőkkel együtt*
- Hasonló eredmények
  - *300 ezer teszt adaton*
- Modell méretek:
  - *kNN: 120 MB*
  - *RFC: 295 MB*
  - ***MLP**: 12 KB*

Osztályozás eredménye

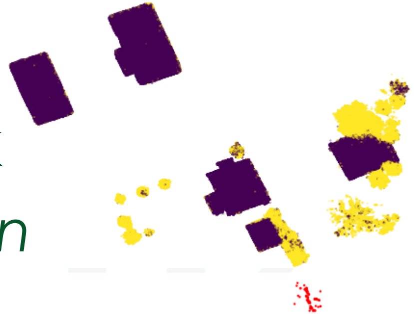

Eltérések

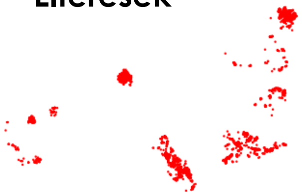

```
kNN
Model accuracy score: 0.99

              precision    recall  f1-score

       Roofs       1.00      0.99      0.99
  Vegetation       0.97      0.99      0.98
```

```
RFC
Model accuracy score: 0.98

              precision    recall  f1-score

       Roofs       0.99      0.99      0.99
  Vegetation       0.95      0.96      0.95
```

```
MLP
Model accuracy score: 0.97

              precision    recall  f1-score

       Roofs       0.98      0.99      0.98
  Vegetation       0.94      0.94      0.94
```

Választás: Multi-Layer Perceptron

TANÍTÓ ADATOK

- Manuális címkézés
  - Tető
    - 2 688 803 db
  - Növényzet
    - 1 519 365 db

TANÍTÁS, MODELL ELŐÁLLÍTÁS

- Multi-Layer Perceptron modell
  - *Rectified Linear Unit (ReLU)*
  - *Bemeneti réteg: 12 db*
  - *Rejtett réteg: 1 db → 15 db neuron*
  - *Kimeneti réteg: 2 db*
  - *Adaptive Moment Estimation (ADAM)*
  - *Learning rate: 0.001*
- Mennyire „jó" a modell?
  - *Accuracy: 97,4%*
  - *Pecision: 98% (t); 96(v)*
  - *Recall: 98% (t); 97% (v)*
  - *F1-score: 98% (t); 96% (v)*

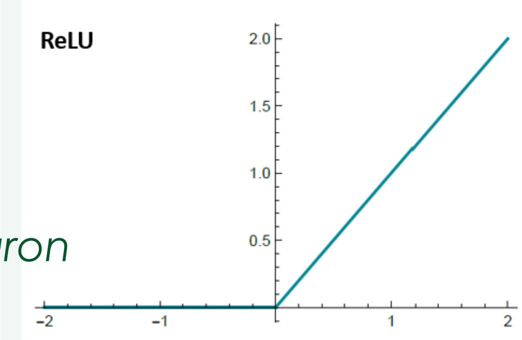

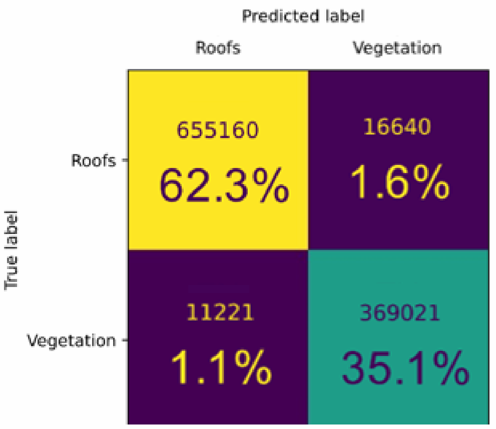

Features
Relative height
RGB values
Omnivariance
Anisotropy
Planarity
Surface variation
Sphericity
Number of neighbors
Surface density
Normal change rate

MODELL ALKALMAZÁSA

Barnag

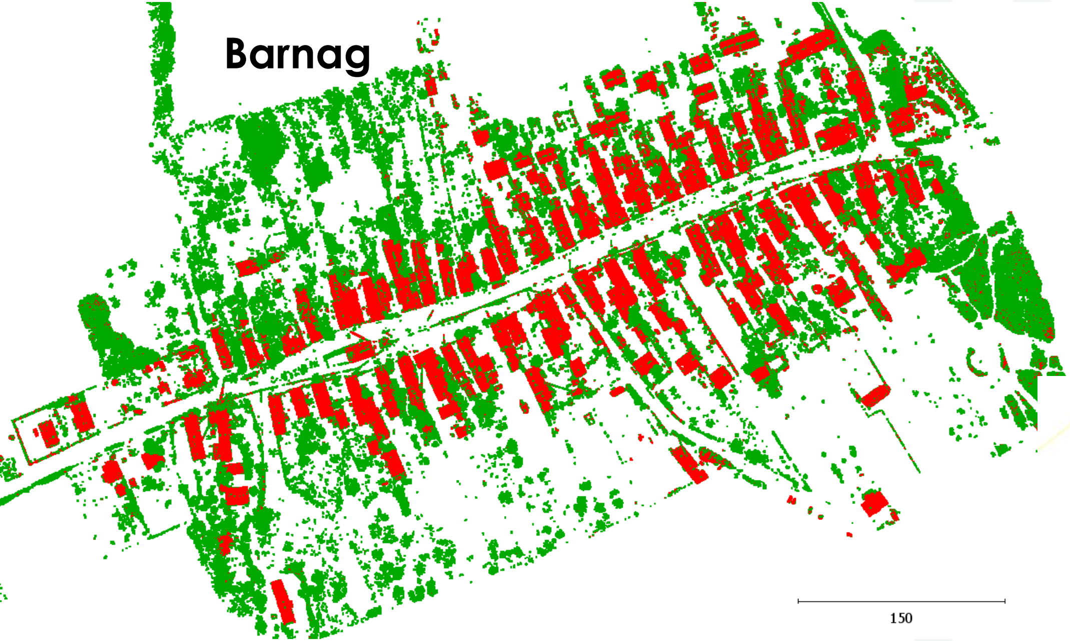

Sződ

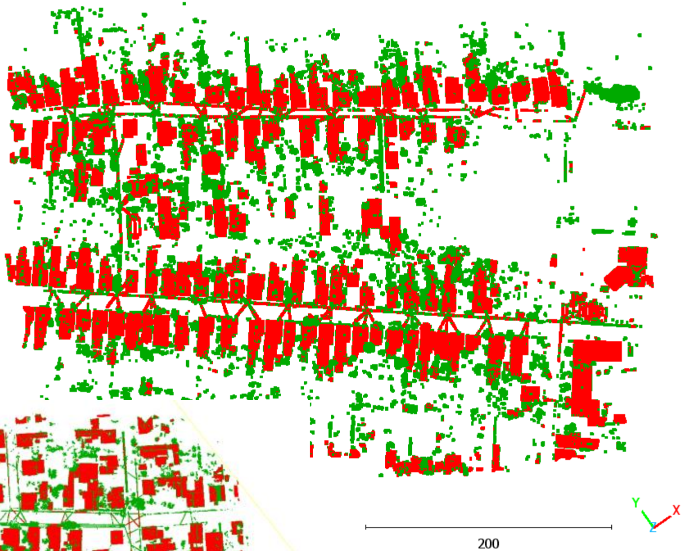

Üllő

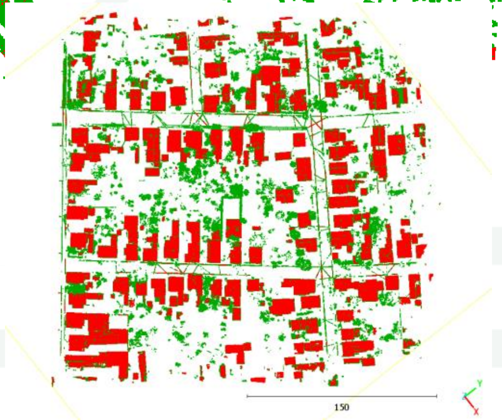

Eredmények közelebbről

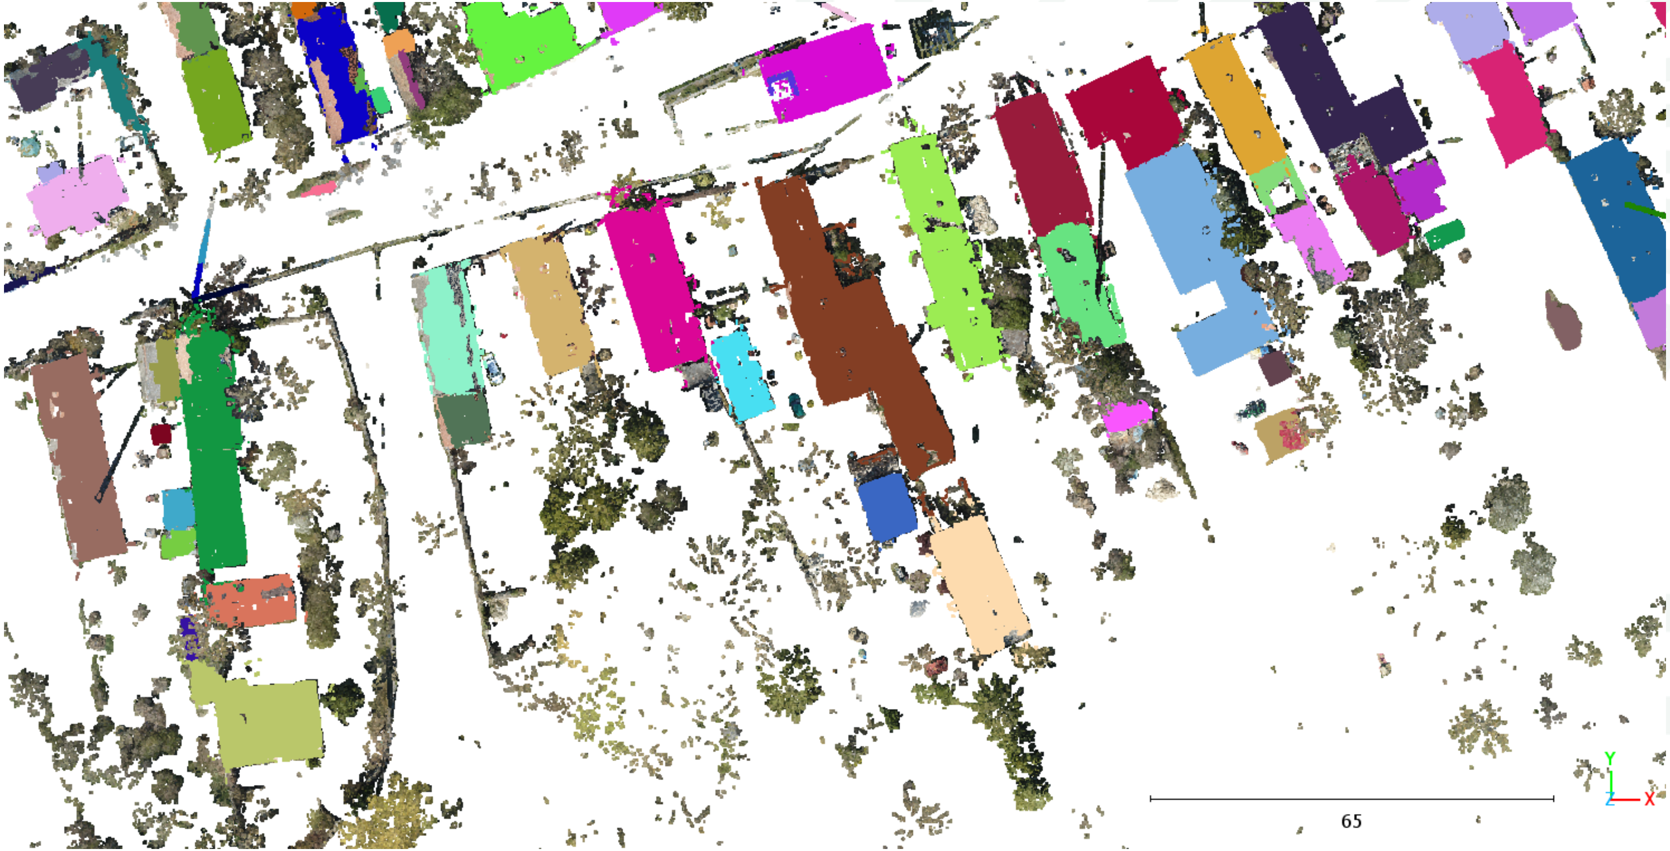

EREDMÉNYEK KÖZELEBBRŐL

Felügyelet nélküli gépi tanulás

DBSCAN

- Density-Based Spatial Clustering of Applications with Noise
- Pontsűrűség alapján
- 2 paraméter:
  - *ε – sugár*
  - *n_{min} = min. pontszám*

$$N\left(d\left(\overline{x}_i, \overline{x}_j\right) \leq \varepsilon\right) \geq n_{min}$$

$$d\left(\overline{x}_i, \overline{x}_j\right) \leq \varepsilon$$

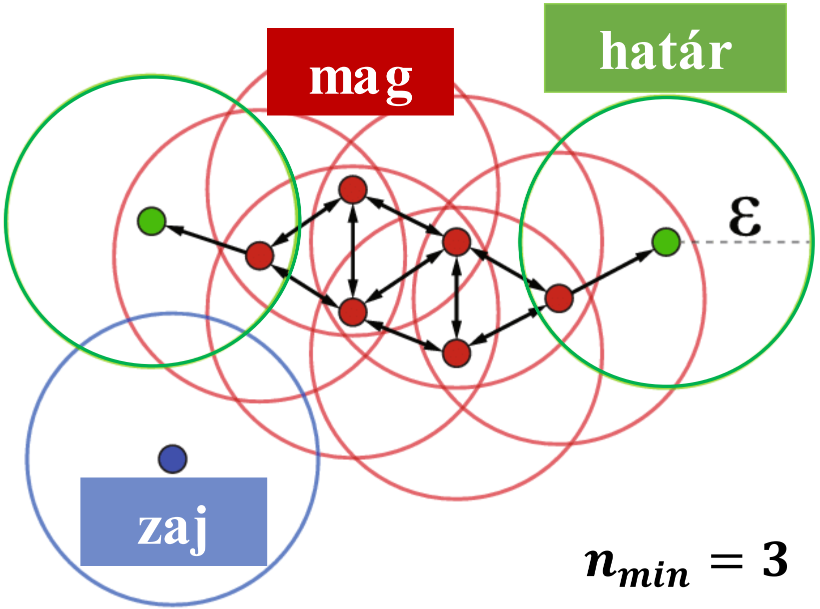

DBSCAN ALKALMAZÁSA

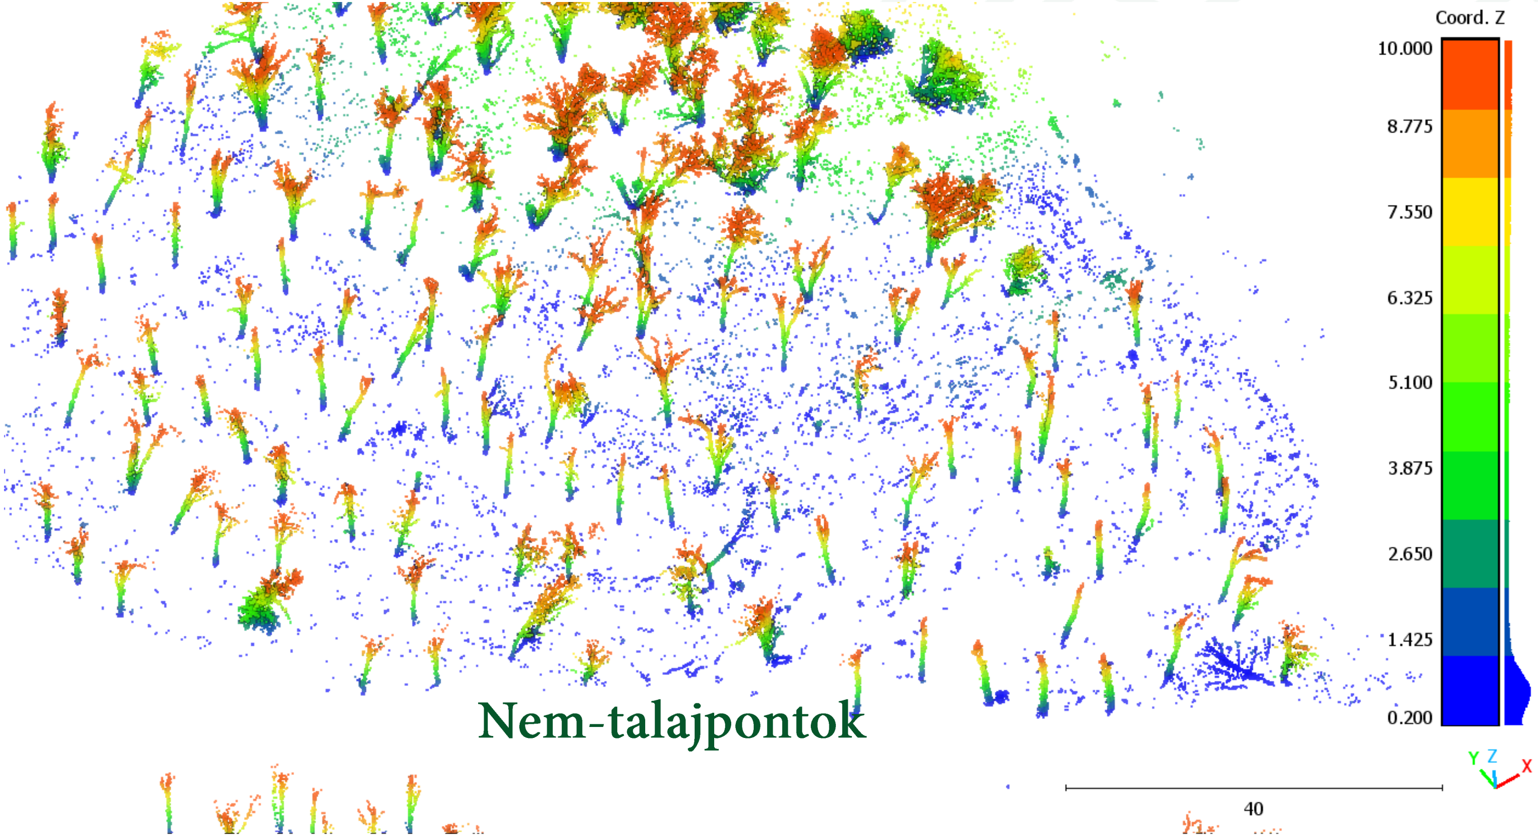

Nem-talajpontok

DBSCAN ALKALMAZÁSA

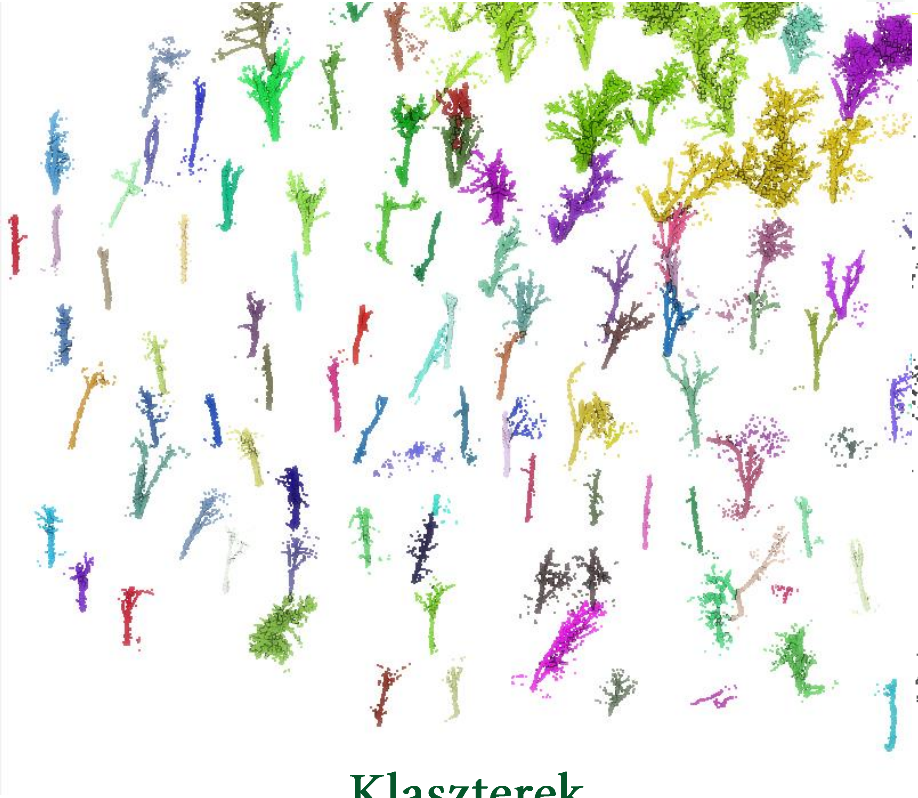

Klaszterek

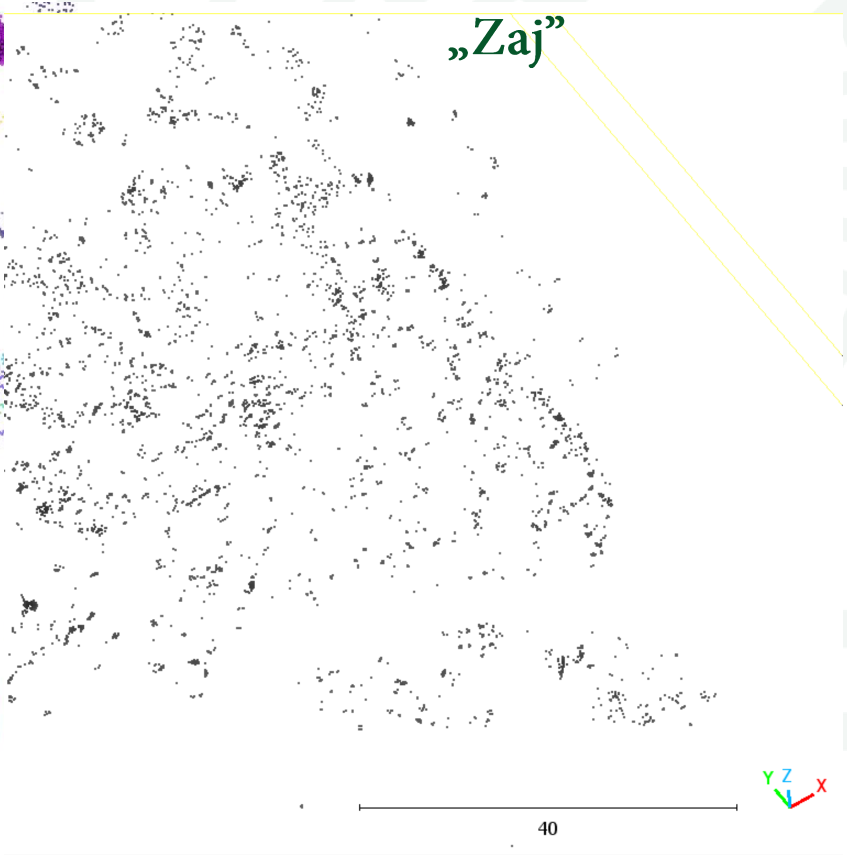

„Zaj”

Egyéb elérhető megoldások

SAJÁTÉRTÉKEKEN ALAPULÓ JELLEMZŐK EGYÉB ALKALMAZÁSA

SAJÁTÉRTÉKEKEN ALAPULÓ JELLEMZŐK EGYÉB ALKALMAZÁSA

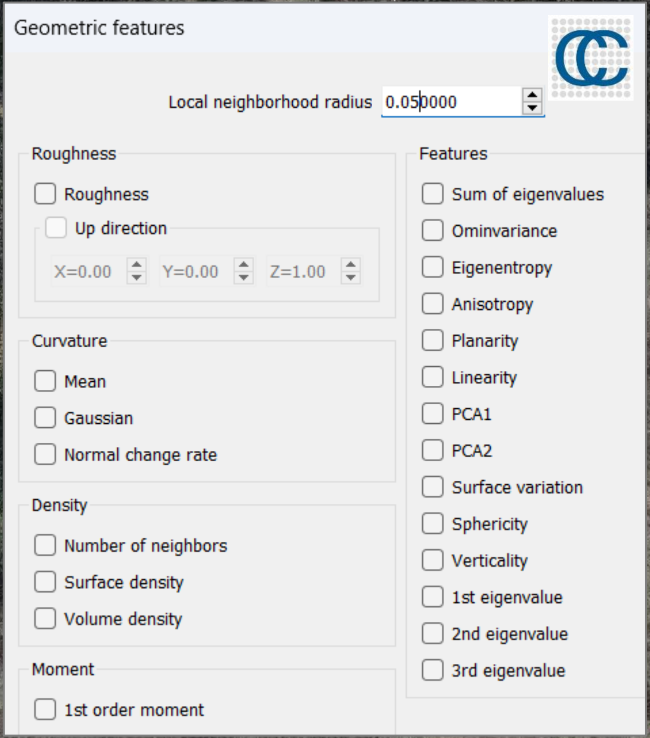

50

SAJÁTÉRTÉKEKEN ALAPULÓ JELLEMZŐK EGYÉB ALKALMAZÁSA

CANUPO

- CAractérisation de NUages de Points
- Pontok osztályozása
- Support Vector Machine (SVM)
  - *Sajátértékeken alapuló jellemzők*
  - *Különböző sugár*

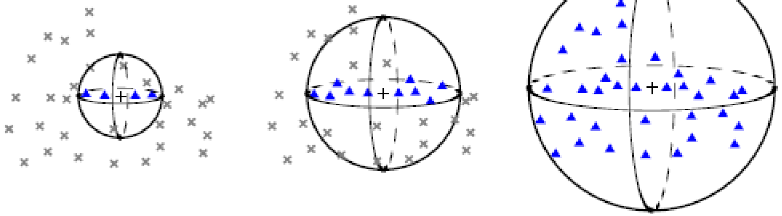

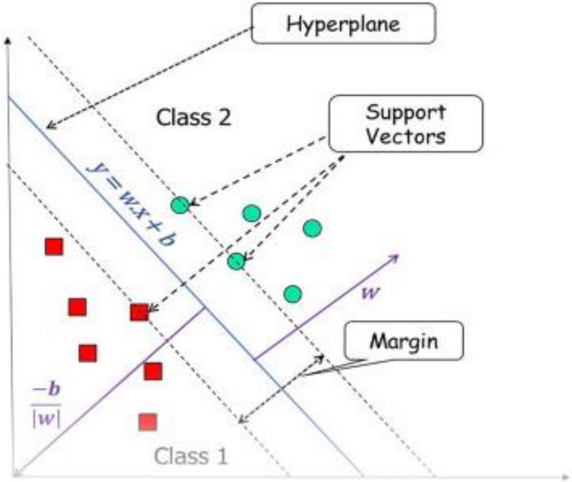

Brodu - Lague 2016.

CANUPO - GYAKORLATBAN

CANUPO - ELŐKÉSZÍTÉS

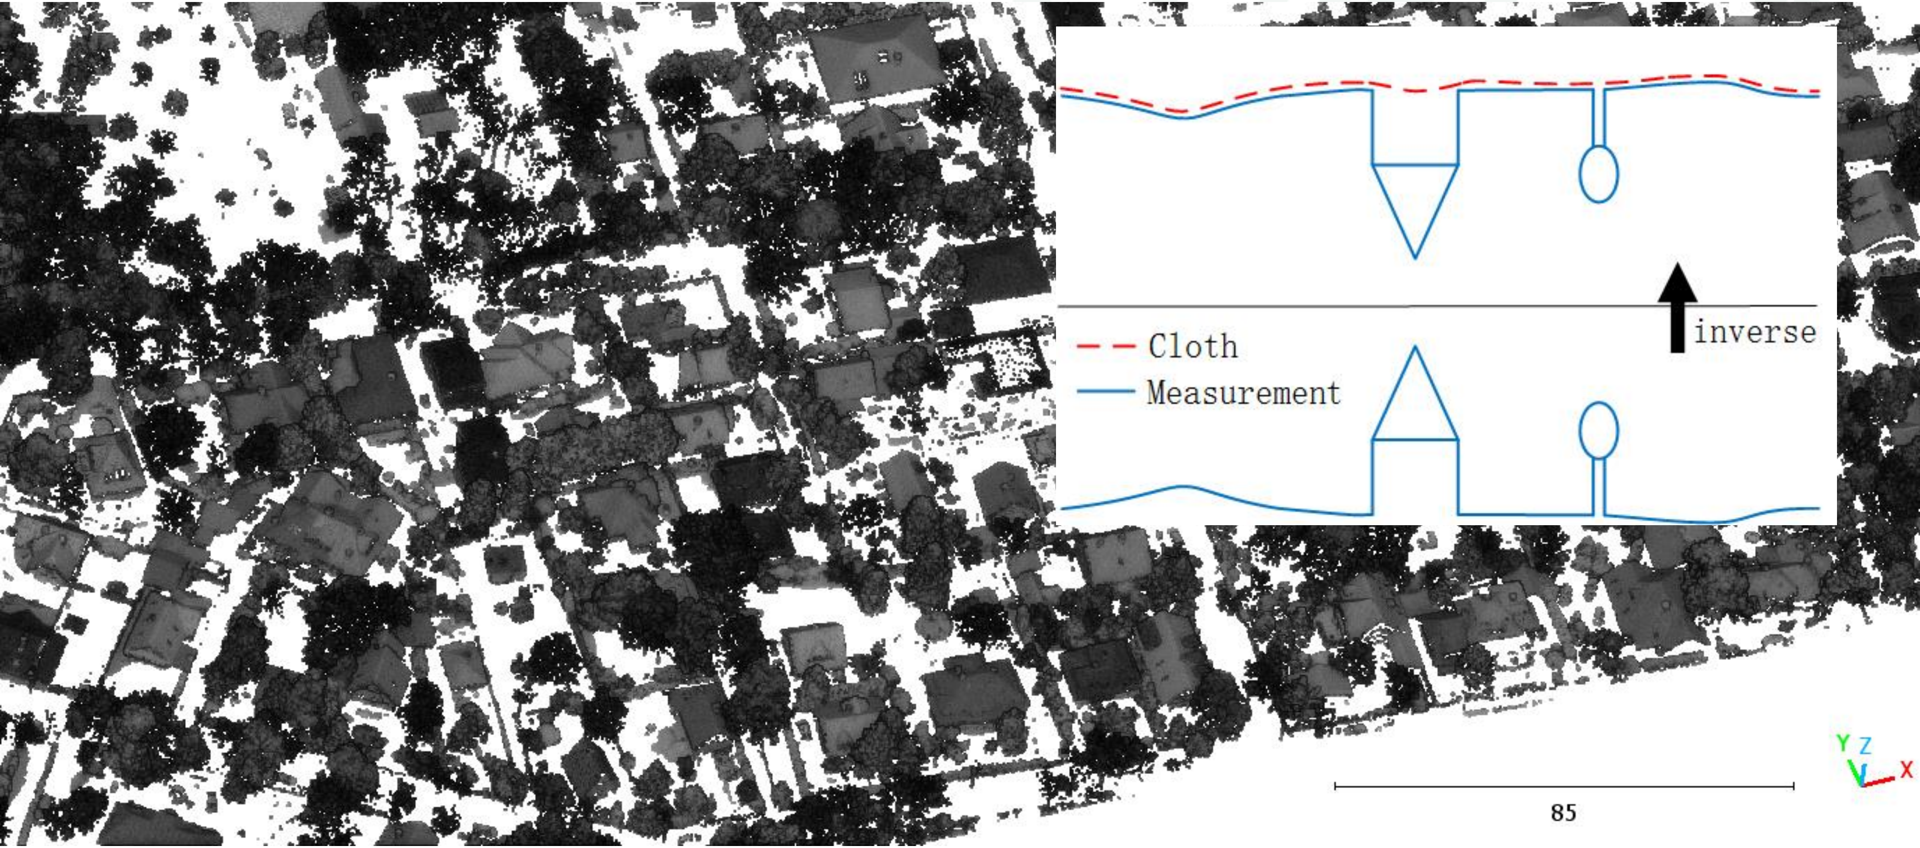

CANUPO - TANÍTÁS

CANUPO - FELHASZNÁLÁS

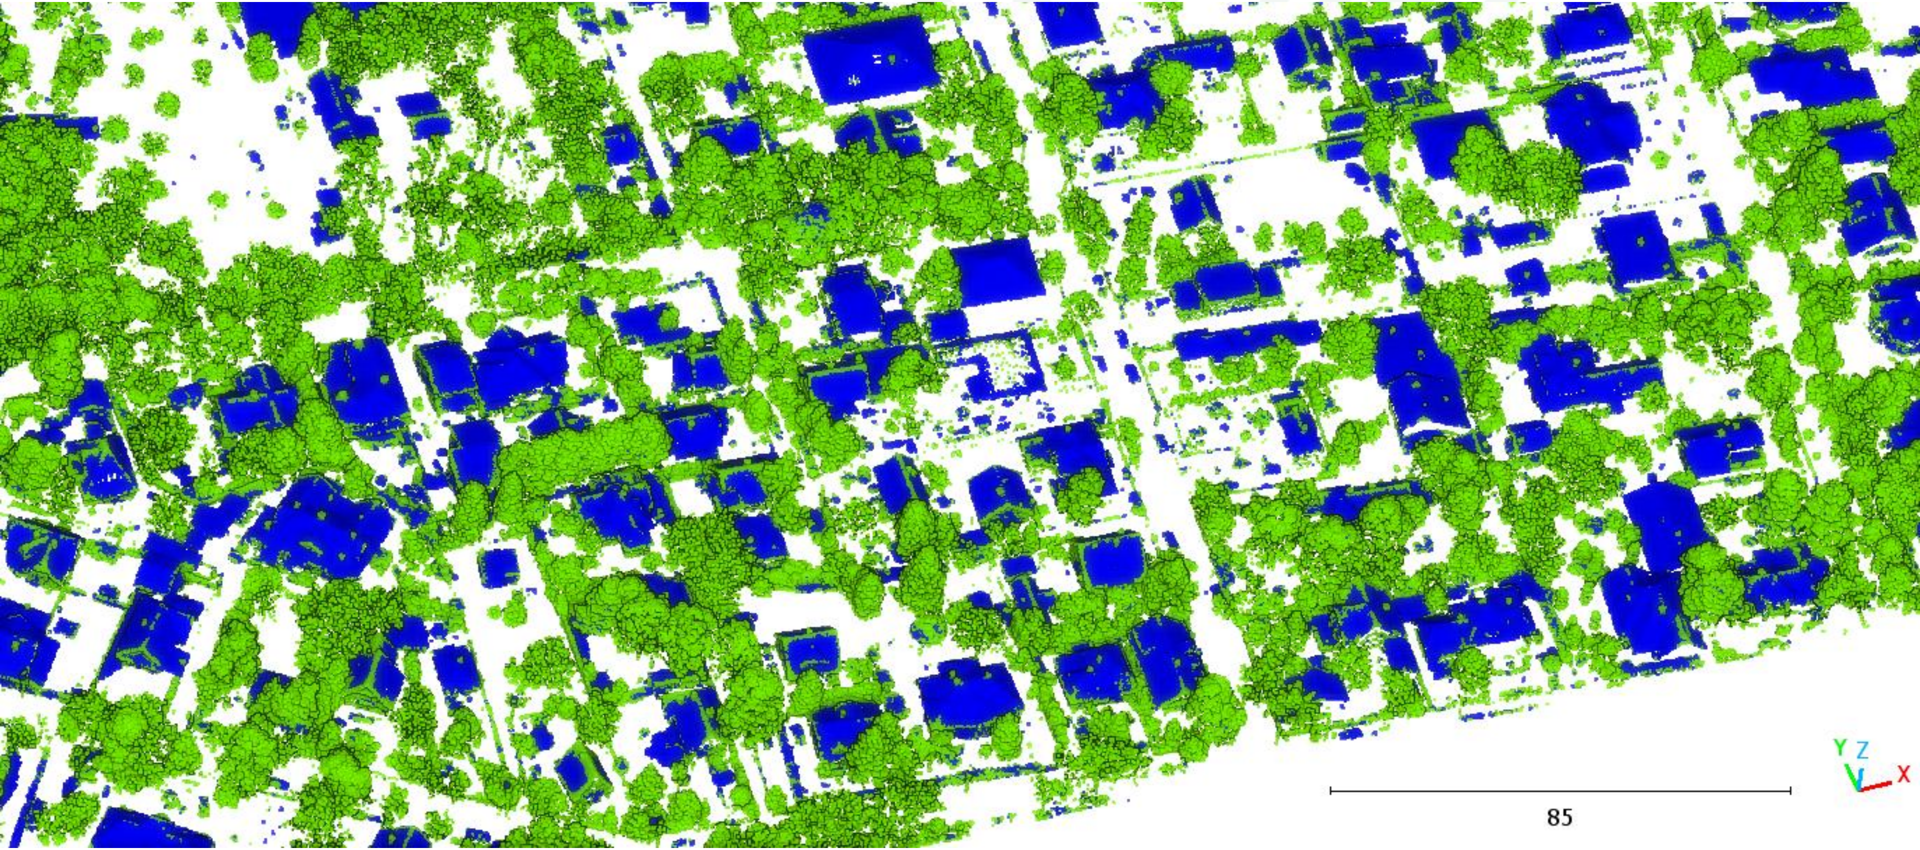

3DMASC

- 3D point classification with Multiple Attributes, Multiple Scales, and Multiple Clouds
- CloudCompare (2.13.beta)
- Osztályozás
- Random Forest Classifier

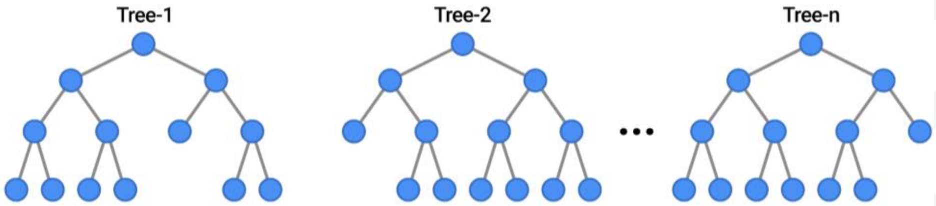

Letard et al. 2023.

3DMASC – MEGADHATÓ JELLEMZŐK

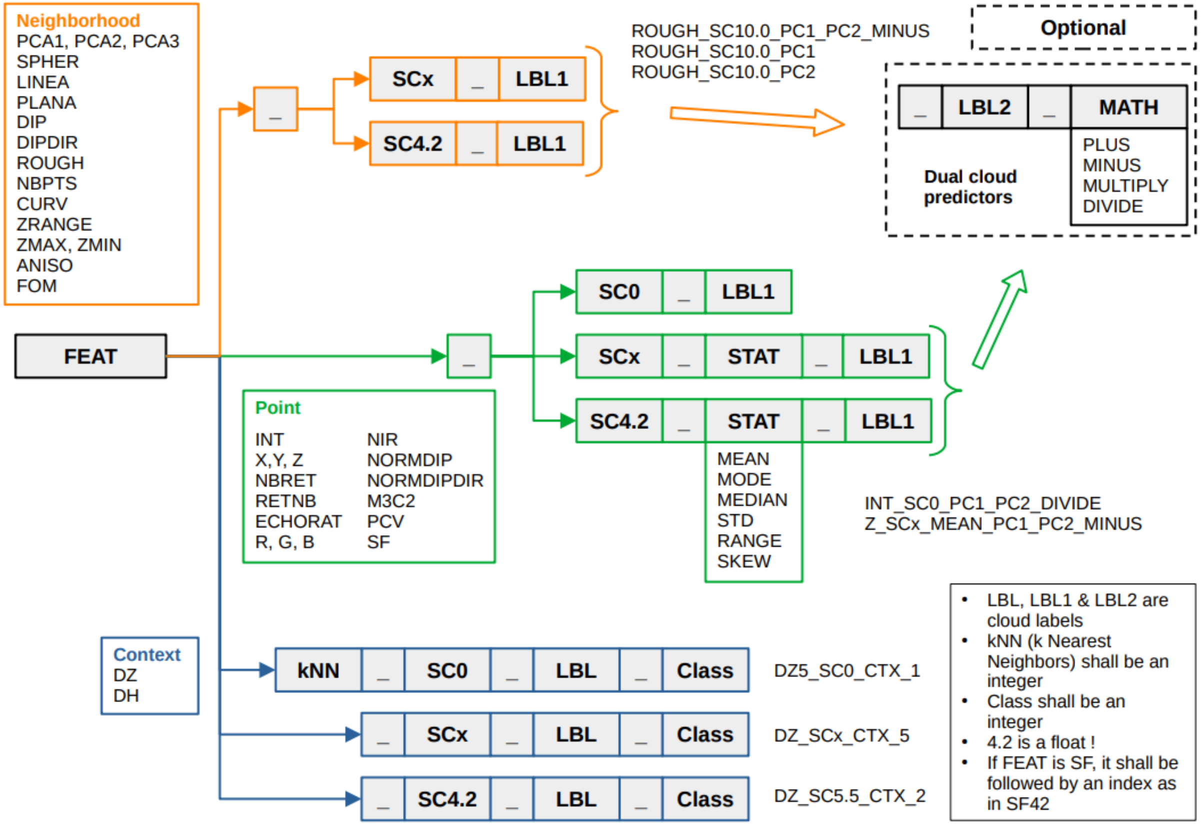

Letard et al. 2023.

3DMASC – ADATOK A TANÍTÁSHOZ

- Toronto 3D
  - *Road (label 1)*
  - *Road marking (label 2)*
  - *Natural (label 3)*
  - *Building (label 4)*
  - *Utility line (label 5)*
  - *Pole (label 6)*
  - *Car (label 7)*
  - *Fence (label 8)*
  - *Unclassified (label 0)*

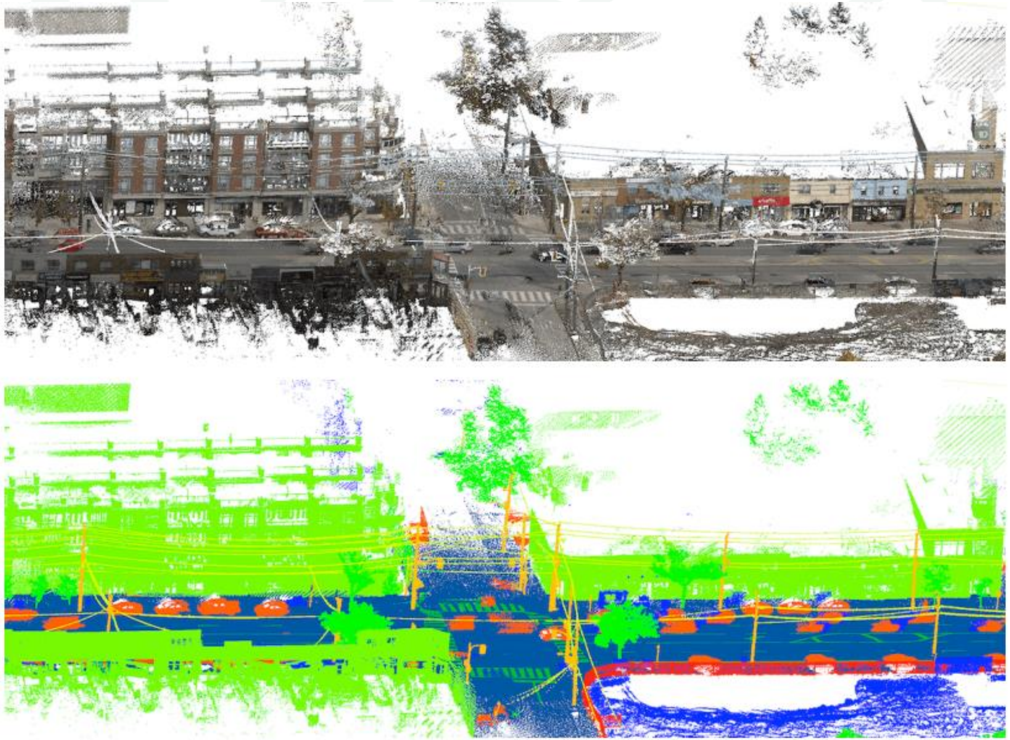

Tan et al. 2020.

3DMASC – TANÍTÁS

NAMES
cloud: PC1=

CORE POINTS
core_points: PC1

SCALES
scales: 0.25;0.5;1

FEATURES
feature: Z_SC0.5_STD_PC1
feature: DIP_SCx_PC1
feature: ROUGH_SCx_PC1
feature: ANISO_SCx_PC1
feature: SPHER_SCx_PC1
feature: LINEA_SCx_PC1
feature: PLANA_SCx_PC1

Road (label 1)
Road marking (label 2)
Natural (label 3)
Building (label 4)
Utility line (label 5)
Pole (label 6)
Car (label 7)
Fence (label 8)
Unclassified (label 0)

Form

		Predicted											
		0	**1**	**2**	**3**	**4**	**5**	**6**	**7**	**8**	**Precision**	**Recall**	**F1-score**
Real	**0**	19873	636	0	1899	128	0	8	78	0	0.94	0.88	0.91
	1	487	80002	245	310	41	4	7	229	4	0.96	0.98	0.97
	2	0	1492	2516	0	0	0	0	4	0	0.91	0.63	0.74
	3	411	525	0	113754	1076	17	19	65	0	0.93	0.98	0.95
	4	218	168	0	5705	28986	2	7	36	0	0.95	0.83	0.88
	5	0	0	0	206	27	2292	14	1	0	0.99	0.9	0.94
	6	43	11	0	382	114	11	1700	6	0	0.97	0.75	0.84
	7	37	325	0	454	20	0	3	7620	0	0.95	0.9	0.92
	8	8	7	0	99	101	0	2	20	228	0.98	0.49	0.65

Overall accuracy 0.94

3dmasc_20231108_16h13 / 1

3DMASC - EREDMÉNYEK

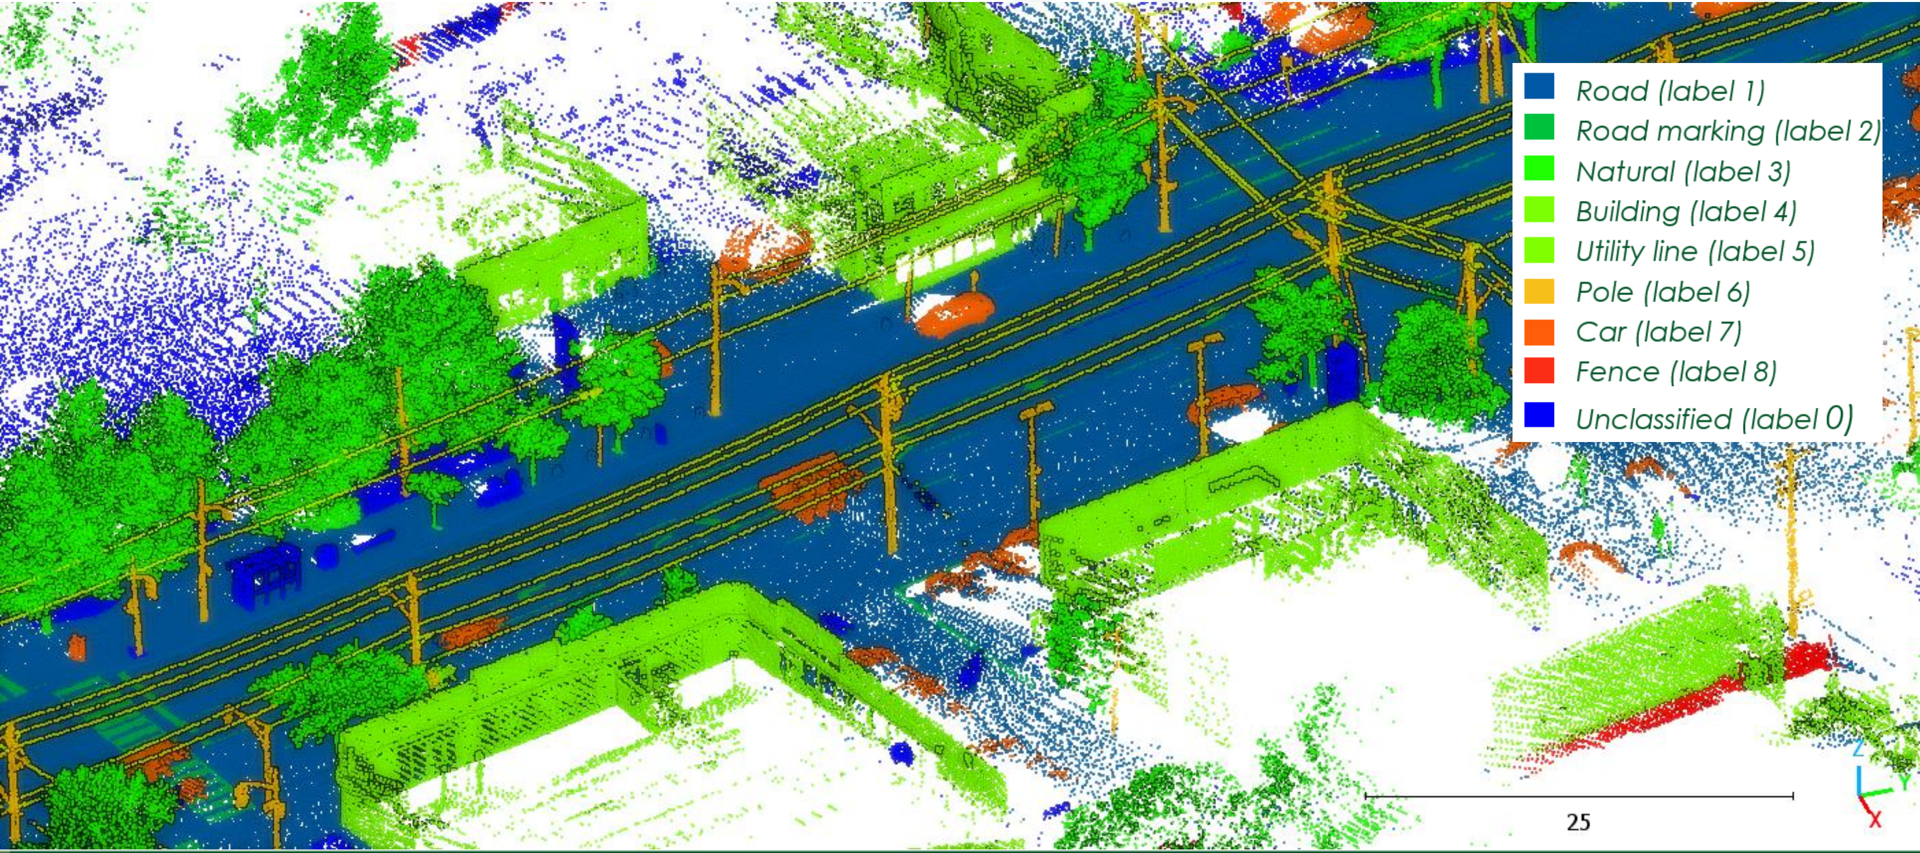

3DMASC - EREDMÉNYEK

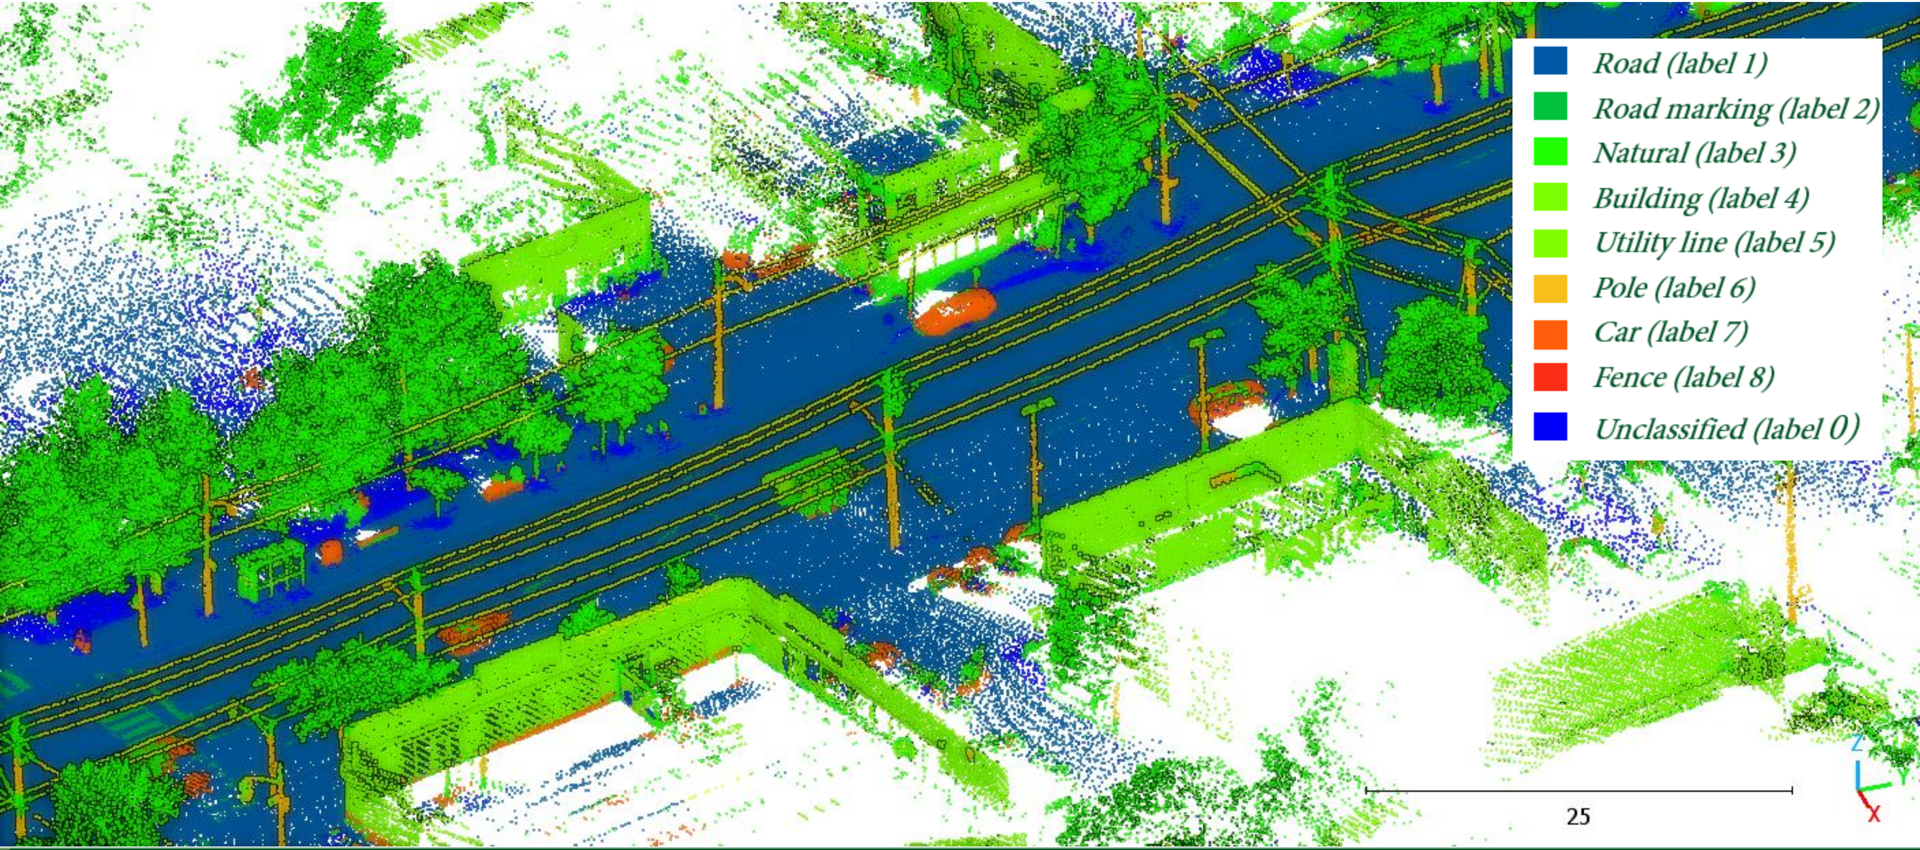

3DMASC - EREDMÉNYEK

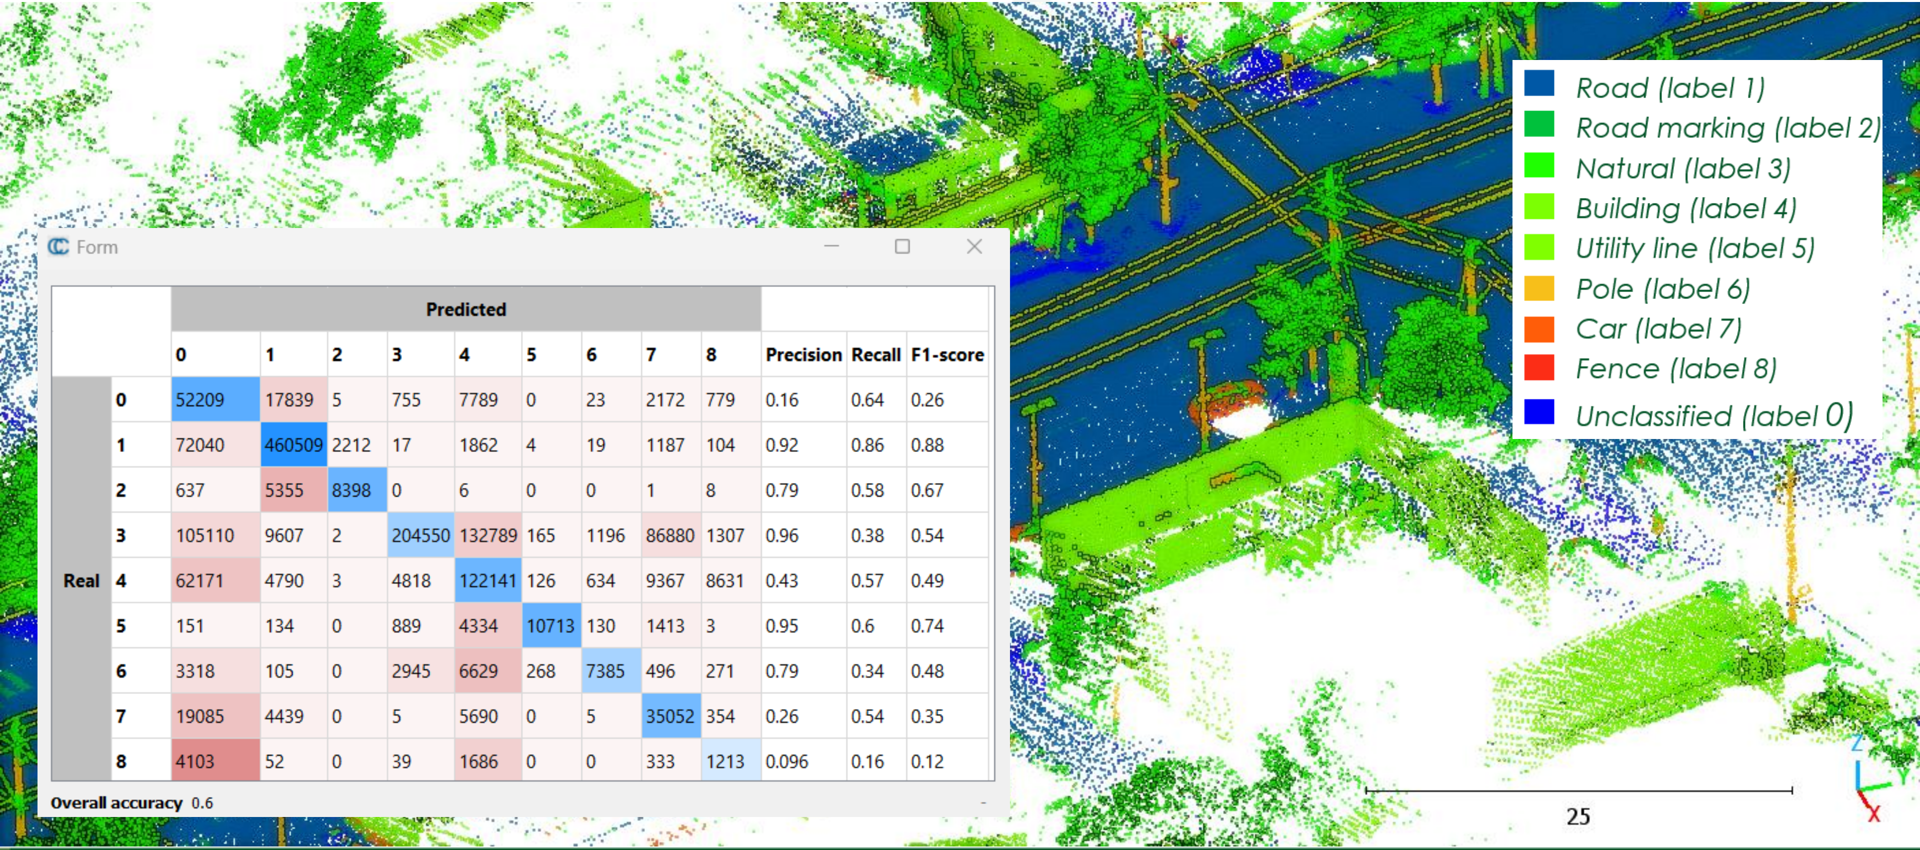

Form

		Predicted											
		0	1	2	3	4	5	6	7	8	Precision	Recall	F1-score
Real	0	52209	17839	5	755	7789	0	23	2172	779	0.16	0.64	0.26
	1	72040	460509	2212	17	1862	4	19	1187	104	0.92	0.86	0.88
	2	637	5355	8398	0	6	0	0	1	8	0.79	0.58	0.67
	3	105110	9607	2	204550	132789	165	1196	86880	1307	0.96	0.38	0.54
	4	62171	4790	3	4818	122141	126	634	9367	8631	0.43	0.57	0.49
	5	151	134	0	889	4334	10713	130	1413	3	0.95	0.6	0.74
	6	3318	105	0	2945	6629	268	7385	496	271	0.79	0.34	0.48
	7	19085	4439	0	5	5690	0	5	35052	354	0.26	0.54	0.35
	8	4103	52	0	39	1686	0	0	333	1213	0.096	0.16	0.12

Overall accuracy 0.6

Osztályozás kereskedelmi szoftverekben

Agisoft Metashape

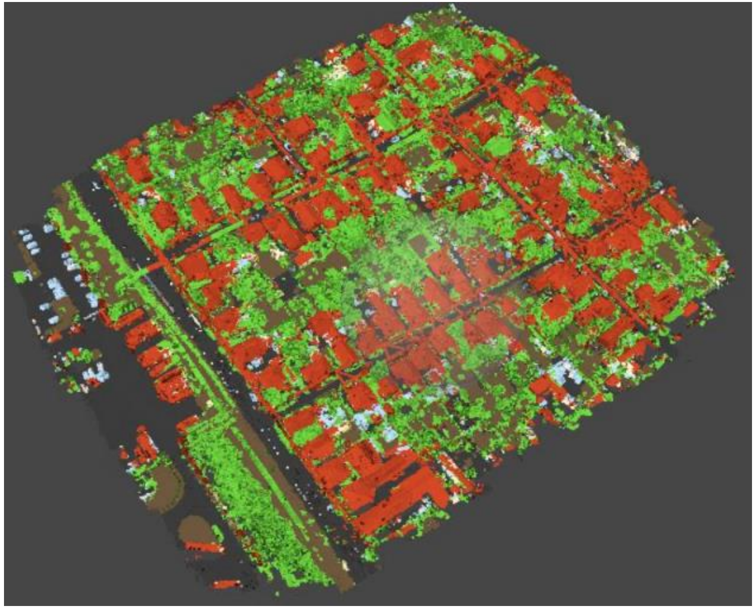

Trimble Business Center

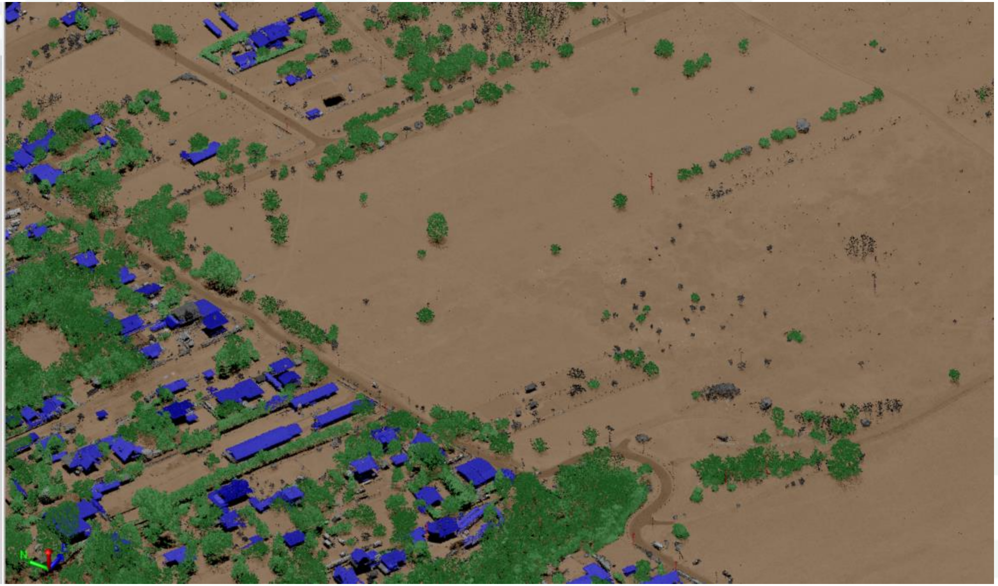

MÉLYTANULÁS

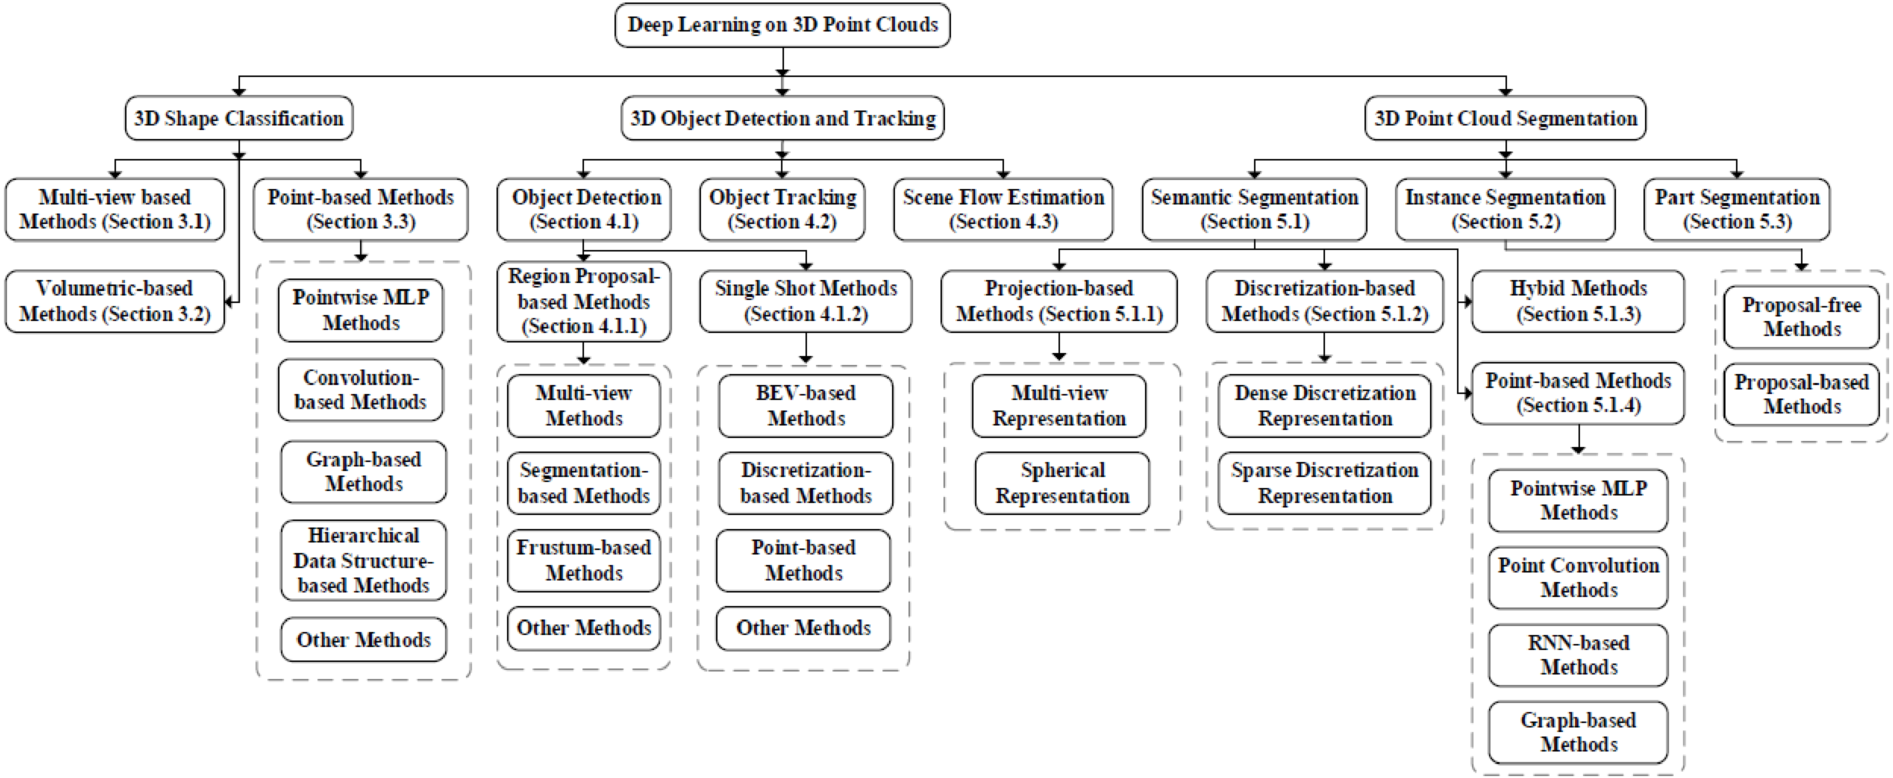

Guo et al. 2020.

ADATKÉSZLETEK

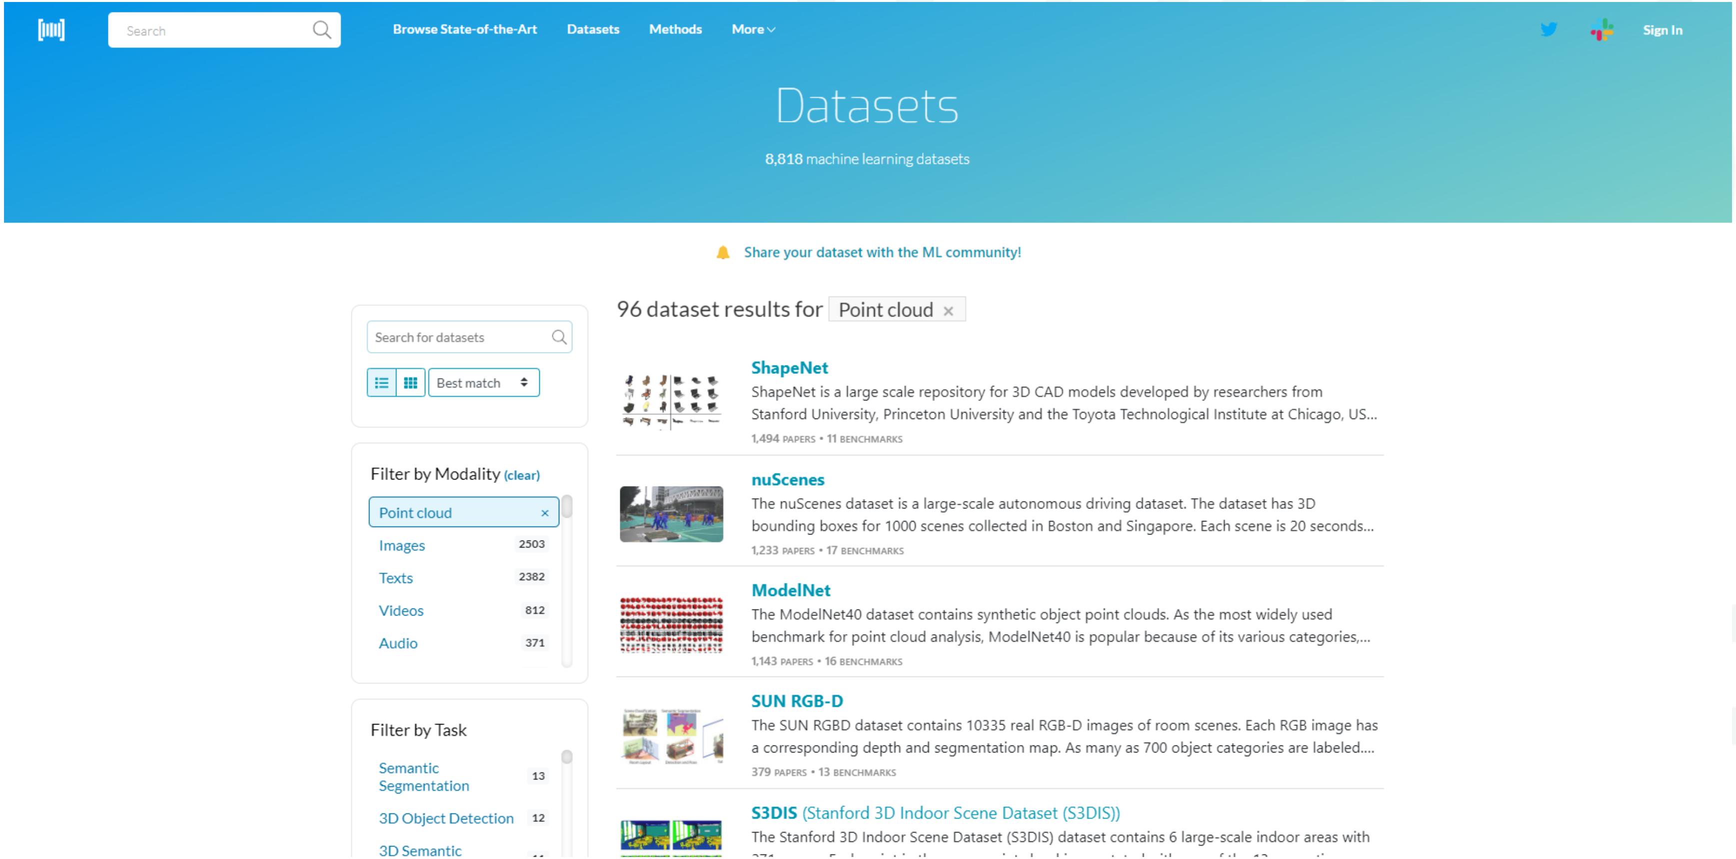

Összegzés

- Gépi tanulás
- Pontfelhő szegmentálás
- Módszerek
- További tervek
  - *Gépi tanulás*
    - Pont vagy ponthalmaz
    - Deep Learning
  - *LOD1 → LOD2*

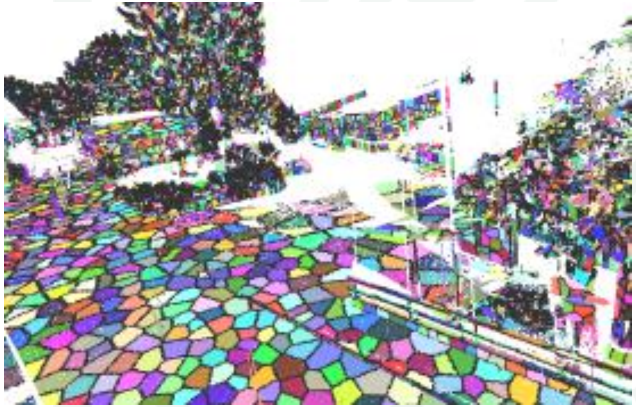

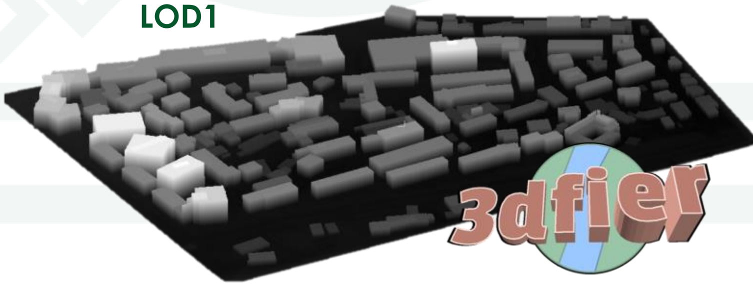

Forrás: Bátori Boglárka TDK dolgozata

Köszönöm a figyelmet!

IRODALOMJEGYZÉK

- Awange, J. - Paláncz, B. - Völgyesi, L. 2020. *Hybrid Imaging and Visualization Employing Machine Learning with Mathematica – Python*. Springer, ISBN 978-3-030-26152-8. https://link.springer.com/book/10.1007/978-3-030-26153-5, utolsó elérés: 2023. november 9.
- Bonaccorso, G. 2018. *Machine Learning Algorithms - Second Edition*. Packt, ISBN 9781789347999. https://www.packtpub.com/product/machine-learning-algorithms-second-edition/9781789347999, utolsó elérés: 2023. november 9.
- Brodu, N. – Lague, D. 2012. 3D Terrestrial lidar data classification of complex natural scenes using a multi-scale dimensionality criterion: applications in geomorphology. https://doi.org/10.48550/arXiv.1107.0550
- Ester, M. - Kriegel, H. P. - Sander, J. - Xiaowei, Xu. 1996. *A Density-Based Algorithm for Discovering Clusters in Large Spatial Databases with Noise*. https://www.osti.gov/biblio/421283, utolsó elérés: 2023. november 9.
- Feng, C. C., Guo, Z. "Automating Parameter Learning for Classifying Terrestrial LiDAR Point Cloud Using 2D Land Cover Maps", Remote Sensing, 10(8), pp. 1192. 2018. https://doi.org/10.3390/rs10081192
- Guo, Y. - Wang, H. - Hu, Q. - Liu, H. - Liu, L. - Bennamoun, M. 2020. Deep Learning for 3D Point Clouds: A Survey. IEEE Transactions on Pattern Analysis and Machine Intelligence. PP. 1-1. 10.1109/TPAMI.2020.3005434. http://dx.doi.org/10.1109/TPAMI.2020.3005434

Irodalomjegyzék

- Letard, M. - Lague, D. - Le Guennec, A. - Lefèvre, S. - Feldmann, B. 2023. 3DMASC: Accessible, explainable 3D point clouds classification. Application to Bi-Spectral TopoBathymetric lidar data. 2023. https://hal.science/hal-04072068. utolsó elérés: 2023. november 9.
- Mayr, A. - Rutzinger, M. - Bremer, M. - Elberink, S. O. - Stumpf, F. - Geitner, C. 2017. Object-based classification of terrestrial laser scanning point clouds for landslide monitoring. The Photogrammetric Record 32(160), pp. 377–397. https://doi.org/10.1111/phor.12215
- Poux, F. – Billen, R. 2019. Voxel-based 3D Point Cloud Semantic Segmentation: Unsupervised Geometric and Relationship Featuring vs Deep Learning Methods. ISPRS International Journal of Geo-Information. 8(5), pp. 213. https://doi.org/10.3390/ijgi8050213
- Tan, W. - Qin, N. - Ma, L. - Li, Y. - Du, J. - Cai, G. - Yang, K. - Li, J. 2020. Toronto-3D: A Large-Scale Mobile LiDAR Dataset for Semantic Segmentation of Urban Roadways. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR) Workshops, 2020, pp. 202-203. https://github.com/WeikaiTan/Toronto-3D. utolsó elérés: 2023. november 9.
- Zhang, W. - Qi, J. - Wan, P. - Wang, H. - Xie, D. - Wang, X. - Yan, G. 2016. *An Easy-to-Use Airborne LiDAR Data Filtering Method Based on Cloth Simulation*. Remote Sensing, 8(6), pp. 1–22. https://doi.org/10.3390/rs8060501