

Pontfelhők szegmentálása mesterséges intelligenciával

Point Cloud Segmentation with AI

dr. SIKI Zoltán, HRUTKA Bence

Általános és Felsőgeodézia Tanszék, Építőmérnöki Kar,
Budapesti Műszaki és Gazdaságtudományi Egyetem,
Műegyetem rkp. 3.,
H-1111 Budapest, Magyarország

Abstract

We present a semantic segmentation method based on machine learning techniques for the automated detection of buildings from point clouds generated through photogrammetric processing. We employed Random Forest and neural network-based classification, combined with DBSCAN clustering. Processing two rural test areas, we successfully segmented more than 90% of the buildings.

Keywords: point clouds, machine learning, deep learning, semantic segmentation

Kivonat

Egy gépi tanulási módszereken alapuló szemantikus szegmentáló eljárást mutatunk be fotogrammetria feldolgozással előállított pontfelhőkből az épületek automatizált megtalálására. Random forest illetve neurális hálózat alapú osztályozást valamint DBSCAN csoportképzést alkalmaztunk. Két falusias mintaterület feldolgozása során az épületek több mint 90 százalékát sikerült szegmentálni.

Kulcsszavak: pontfelhő, gépi tanulás, mély tanulás, szemantikus szegmentáció

1. BEVEZETÉS

A korszerű nagy tömegű pontot előállító adatgyűjtési módszerek – mint a légi lézer szkennerek (ALS), a földi lézer szkennerek (TLS) és a mobil térképező rendszerek (MMS) és a drón fotogrammetria – a terepi adatgyűjtést felgyorsították és a hagyományos módszerekhez képest sokkalta részletgazdagabbá tették azt. Másrészt viszont a földmérési munkákat megrendelők többsége számára nem megfelelők ezekkel a módszerekkel előállított strukturálatlan pontfelhők. Egy strukturált állományt kérnek, mely a számukra szükséges objektumokat tartalmazza. A manuális feldolgozás mellett széles körű kutatási terület nyílt meg a kívánt objektumok, különböző információk automatizált kinyerésére a pontfelhőkből.

Cikkünkben a pontfelhők automatizált feldolgozására mutatunk be megoldást mesterséges intelligencia, illetve mély tanulási módszer felhasználásával. A kidolgozott megoldás során az épületek szegmentálására illetve a térképen feltüntetendő körvonaluk automatizált megtalálására koncentrálnak.

A drón (UAV) fotogrammetria az elmúlt évtizedben a térkép- és kataszteri felújítás egyik ígéretes eszközévé vált. Több nemzetközi példa is igazolja a módszer alkalmazhatóságát: a hollandiai kísérlet [11] elsőként mutatta ki, hogy UAV-alapú pontfelhőkkel és valódi ortofotókkal a telekhatárok azonosíthatók, és az ingatlan-nyilvántartási térképezéshez szükséges pontosság – 10 cm alatt – elérhető. Hasonló eredményekre jutottak albániai [8] és lengyelországi [9] vizsgálatokban is. A fotogrammetria mellett a drónra szerelt LiDAR-érzékelők szintén bizonyított eszköznek számítanak: He és Li [4], valamint egy csehországi összehasonlító vizsgálat [12] egyaránt megerősítette, hogy mindkét technológia teljesíti a kataszteri pontossági követelményeket.

Magyarországon is történtek hasonló vizsgálatok, a Magyar Mérnöki Kamara Geodéziai és Geoinformatikai Tagozat 2020-ban készített egy tanulmányt [5] az elavult ingatlan-nyilvántartási térképek korszerű technológiákkal végzett felújítására, melyben a fotogrammetriai módszerrel előállított pontfelhő feldolgozása manuálisan történt meg. Jelen cikk ennek a munkának a folytatása, a pontfelhő automatizált

feldolgozásának irányába. A munkában Barnag község belterületére elkészített pontfelhő egy részét mintaterületként felhasználtuk.

Céljaink elérése érdekében olyan pontfelhők előállítására van szükség, melyekben az épületek oldalfalán is kellő számú pont leképződik, a közterületekről nem látható oldalakon is. Ilyen pontfelhők előállításához a légi módszerek a megfelelőek, elsősorban a ferde tengelyű (oblique) drónról készített felvételekből nyerhetünk megfelelő információt. A munkánk során jellemzően szabadon álló, családi házas beépítésű területekre koncentrálnak és ennek megfelelő mintaterületeket használtunk fel.

Többféle megoldást írtak már le a szakirodalomban [3, 7, 8], ezek döntő többsége a tető alakzatok kinyerésére koncentrálnak.


A mesterséges intelligencia megoldásai [1] közül a felügyelt és a felügyelet nélküli módszereket is alkalmaztunk (random forest, neurális hálózat, DBSCAN, RANSAC). Az adatfeldolgozás során a CloudCompare programot, a Scikit-learn és keras programkönyvtárakat valamint saját Python nyelven írt programokat használtunk.

A megoldásunk során a szemantikus szegmentáció módszerét választottuk. Ez egyrészt egy osztályozásból áll, melynek során minden egyes pontot előre meghatározott osztályokba sorolunk, majd az osztályokon belül ugyanahhoz az objektumhoz tartozó pontokat rendezzük egy csoportba.

A 75-80% százalékos átfedésű függőleges és ferde tengelyű drón felvételekből néhány centiméteres sűrűségű pontfelhőt kapunk. Például a Barnag esetében egy 50 hektárt meghaladó területre a fotogrammetriai feldolgozás után 450 millió pontot tartalmazó, 12 GB méretű pontfelhőt kaptunk 2 cm alatti terepi felbontással (GSD) bíró felvételekből. A pontsűrűség erősen inhomogén, az épületek automatizált osztályozásához és szegmentálásához különösen kedvezőtlen, hogy a nagyon nagy számú tető pontok mellett nagyon kevés pont képződött le a falakon, körülbelül 15:1 arányban.

2. ELŐFELDOLGOZÁS

Az előfeldolgozás (1. ábra) során az elsődleges cél, hogy a feldolgozásunk szempontjából lényegtelen pontokat eltávolítsuk a pontfelhőből. Ez egyrészt a pontfelhő méretét csökkenti, másrészt a későbbi feldolgozást egyszerűsítheti és hatékonyabbá teheti. A zajszűrési eljárások, mint például a statisztikai kilógó érték eltávolítás (SOR), sugaras kiugró érték eltávolítás (ROR), néhány százalékkal csökkentik jellemzően a pontfelhők méretét. A pontfelhő ritkításával (szomszédos távolság vagy voxel alapon) nagyobb csökkentést érhetünk el, de óvatosan kell eljárni, mert a feldolgozás szempontjából értékes pontokat is kivehetünk az adatállományból. A pontfelhő méretét inkább, a későbbiek során szükségtelen talaj pontok eltávolításával csökkenthetjük hatékonyan. A CSF algoritmus [2, 13] segítségével két részre, talaj és nem talaj pontokra bontjuk fel a szűrt pontfelhőt. Ezzel családi házas környezetben 50-60%-os pontszám csökkenést érhetünk el.



1. ábra Az előfeldolgozás folyamata

Elsősorban a tető különválasztásához, a talajfelszín feletti relatív magasságok többlet információt szolgáltatnak, ezért a leválasztott talajpontokból egy digitális domborzatmodellt hozunk létre, melynek magasságait kivonjuk a nem talaj pontok magasságaiból [6]. Így egy normalizált felszín modellt (nDSM) állítunk elő a nem talaj pontokra (2. ábra). A feldolgozás további lépéseiben ebből indulunk ki.




2. ábra Felül: eredeti pontfelhő oldalnézetben,
alul normalizálás után

3. SZEMANTIKUS SZEGMENTÁCIÓ

A szemantikus szegmentáció (3. ábra) első lépésében a normalizált nem talaj pontokat osztályozzuk. Erre három eljárást dolgoztunk ki. A RANSAC (RANdom SAMple Consensus) síkokkal operáló nem felügyelt megoldást egy cikkben [6] már bemutattuk. Jelen dokumentumban két felügyelt gépi tanulási módszer alkalmazását mutatjuk be. Mindkét esetben négy osztályhoz készítettünk tanító adatokat (fal, tető, növény, egyéb) két rendelkezésre álló, családi házas mintaterületről. Manuális vágtuk ki az egyes osztályoknak megfelelő pontcsoportokat osztályonként külön fájlokba. Két mintaterületet használtunk fel, az egyik a [5] tanulmány készítése során Barnag község belterületére elkészített állomány 6 ha-os részletét, a másik Sződ belterületének egy 20 ha-os részlete, melyet a tanszék készített kutatási célokra.

Tanító adatok összetétele 1. táblázat

Osztály	Minták száma
Fal	135283
Tető	3528807
Növény	285846
Egyéb	998916



3. ábra A szemantikus szegmentáció folyamata

A fotogrammetria módszerrel előállított pontfelhőkben tárolt adatok (koordináták és szín értékek) nem biztosítanak elegendő információt az osztályozáshoz. Ehhez a pontfelhő egyes pontjaihoz a környezetük alapján további jellemzőket vezetünk le. Az egyes pontok „R” sugarú környezetében található pontokból egy variancia, kovariancia mátrixot álltunk elő, melynek a sajátértékei a pontra vonatkozó, a környezetéből levezetett információt tartalmaz. A sajátértékek számítását három különböző sugar értékkel (0.25, 0.5 és 1 m) is meghatároztuk. Emellett a normalizált magasságokat és a pontok 0.1 m-es környezetéből levezetett normálisok vízszintessel bezárt szögét és a szín értékeket is figyelembe vettük.

3.1. Osztályozás random forest eljárással

Az alkalmazott gépi tanulási módszer, a random forest (véletlen döntési erdő) alkalmazásához további geometriai jellemzők [7] levezetése szükséges a sajátértékekből (2. táblázat), mivel a gépi tanulási módszerek, mély tanulási módszerekkel ellentétben nem képesek a szükséges jellemzők automatizált megtalálására.

Sajátértékekből levezetett geometriai jellemzők 2. táblázat

Megnevezés	Formula ($\lambda_1 \geq \lambda_2 \geq \lambda_3$ sajátértékek)	Megnevezés	Formula ($\lambda_1 \geq \lambda_2 \geq \lambda_3$ sajátértékek)
Anisotropy	$\frac{\lambda_1 - \lambda_3}{\lambda_1}$	PCA2	$\frac{\lambda_2}{\lambda_1 + \lambda_2 + \lambda_3}$
Eigenentropy	$\sum_{i=1}^3 \lambda_i \cdot \ln(\lambda_i)$	Planarity	$\frac{\lambda_2 - \lambda_3}{\lambda_1}$
Linearity	$\frac{\lambda_1 - \lambda_2}{\lambda_1}$	Sphericity	$\frac{\lambda_3}{\lambda_1}$
Omnivariance	$(\lambda_1 \cdot \lambda_2 \cdot \lambda_3)^{1/3}$	Surface variation	$\frac{\lambda_3}{\lambda_1 + \lambda_2 + \lambda_3}$
PCA1	$\frac{\lambda_1}{\lambda_1 + \lambda_2 + \lambda_3}$	Verticality	$1 - e_{3z} $

A random forest algoritmus tanítása közben a 2. táblázatban szereplő valamennyi jellemzőt figyelembe vettük 0.25, 0.5 és 1 méteres sugarakkal. A modell tanításához saját Python programot készítettünk a scikit-learn könyvtár felhasználásával. Az előkészített címkézett adatok 80%-át használtuk a tanításra és 20%-át az ellenőrzésre. Mind a tanítás, mind az ellenőrzésre felhasznált adatokra a modell több 99.5 %-ban helyes választ adott. Az egyes jellemzők fontosságát a 3. táblázatban foglaltuk össze, de csak az 0.1%-nál nagyobb hatású jellemzőket adtuk meg. Ezek az értékek kisebb mértékben megváltozhatnak minden megismételt tanítási folyamat során, a véletlen számok használata miatt. Jól látható, hogy a nagyobb 1 méteres távolságra vonatkozó jellemezők valamint a környezettől független relatív magasság és a normális vízszintessel bezárt szöge van a legnagyobb hatással az osztályozás eredményére. A 0.25 méteres környezet hatása minimális.

A geometriai jellemzők közül a függőlegesség (verticality) kiemelt jelentőséggel bír. Az alacsony hatással bíró geometriai jellemzőket célszerű kihagyni, így mintegy harmadával csökkenthetjük a bemeneti paraméterek számát, 34-ről 24-re, ami az algoritmus hatékonyságát növeli az eredmények minőségének romlása nélkül. A 24 bemeneti paraméterrel megismételt random forest modell tanítása statisztikailag azonos eredményt hozott, de a futási idő kétharmadára csökkent.

A megőrzött paramétereket aláhúzással jelöltük a 3. táblázatban.

Geometriai jellemzők hatása az random forest osztályozásra 3. táblázat

	Távolság [m]		
Megnevezés	0.25	0.5	1
Verticality	<u>7.0 %</u>	<u>11.1 %</u>	<u>14.9 %</u>
Relatív magasság	<u>10.6 %</u>		
Normális szöge	<u>6.8 %</u>		
Kék	<u>4.4 %</u>		
Vörös	<u>3.0 %</u>		
Zöld	<u>2.1 %</u>		
Surface variation	0.1 %	<u>1.7 %</u>	<u>3.4 %</u>
Planarity	0.1 %	<u>2.9 %</u>	<u>2.0 %</u>
Sphericity		<u>1.3 %</u>	<u>2.7 %</u>
PCA1		0.1 %	<u>1.0 %</u>
PCA2	0.1 %	<u>2.4 %</u>	<u>1.9 %</u>
Planarity	0.1 %		<u>2 %</u>
Anisotropy		0.8 %	<u>2.4 %</u>
Eigenentropy	<u>1.4 %</u>	<u>1.8 %</u>	<u>1.4 %</u>
Linearity		<u>1.0 %</u>	<u>1.3 %</u>
Omnivariance		0.1 %	<u>1.0%</u>
Anisotropy		1.2 %	<u>2.4 %</u>

3.2. Osztályozás neurális hálóval

A random forest algoritmus mellett egy mély tanulási megoldást is alkalmaztunk. A neurális hálózatra épülő módszer során nem használtuk fel a sajátértékekből levezett geometriai jellemzőket, hiszen a mély tanulási algoritmusok jellemzője, hogy a fontos jellemzőket képesek felismerni. Így a neurális hálózat bemeneti rétegén a három sajátérték, 0.25, 0.5 és 1 méteres környezetből levezetett értéke mellett a relatív magasság, a normális vízszintessel bezárt szögét és a színeket adtuk meg. Az kimeneti rétegen itt is négy osztály jelenik meg: fal, tető, növény, egyéb. A neurális háló rétegeit a 4. táblázat foglalja össze. A hálózat több mint tízezer tanítható paramétert tartalmaz. A neurális háló modellt egy saját Python programban valósítottuk meg a Keras mély tanulási programkönyvtár felhasználásával.

A betanított neurális hálózat az ellenőrző adatokra 99% feletti arányban adott helyes választ. Az egyes bemeneti paraméterek, a random forest osztályozáshoz hasonlóan, az 1 méteres környezetet figyelembe vevő sajátértékek a dominánsak (5. táblázat), a 0.1 %-nál kisebb hatásokat nem adtuk meg. Itt is jelentős a relatív magasság színek és a normális vízszintessel bezárt szögének a hatása. A neurális hálózattól azt várjuk el, hogy a sajátértékek alapján a geometriai jellemzőket találja meg. A sajátértékeke alacsony hatásából arra következtethetünk, hogy ez kevésbé sikerült. Ennek köszönhető, hogy a többi bementi paraméter hatása kiemelkedően magas.


Neurális hálózat rétegei 4. táblázat

Réteg típus	Neuron szám	Paraméterek száma
Bemeneti réteg	11	-
Rejtett réteg	128	1536
Dropout 20%	-	-
Rejtett réteg	64	8256
Rejtett réteg	16	1040
Kimeneti réteg	4	68

Geometriai jellemzők hatása az neurális hálózat osztályozásra 5. táblázat

Megnevezés	Távolság [m]		
	0.25	0.5	1
Zöld	<u>23.3 %</u>		
Kék	<u>18.3 %</u>		
Vörös	<u>14.5 %</u>		
Relatív magasság	<u>20.5 %</u>		
Normális szöge	3.5 %		
1. sajátérték		0.1 %	0.3 %
2. sajátérték	0.8 %	2.7 %	4.6 %
3. sajátérték	0.5 %	1.2 %	3.7 %

A random forest és a neurális hálózat viszonylag zajos eredményt szolgáltat a mintaterületekre alkalmazva a betanított modelleket. Jellemzően a növényzet különválasztása okoz problémát mindkét esetben (4. ábra).



4. ábra Osztályozás eredménye, balra tető pontok, jobbra fal pontok (random forest)


Random forest és neurális hálózat osztályozás összehasonlítása 6. táblázat

	Random forest	Neurális hálózat
Bemeneti paraméterek száma	38 / 24	14
Modell tanítás [perc]	25	127
Modell alkalmazás [perc]	3	16
Fal pontok száma	862 657 (560 361 közös)	1 239 037
Tető pontok száma	14 612 099 (13 255 010 közös)	14 211 864

A 6. táblázatban jelentős eltérés mutatkozik a két módszer között a fal pontok osztályozásában. A közös pontok azon pontok száma, melyre mindkét osztályozási eljárás azonos eredményt hozott. Csak az egyik osztályozás által fal pontnak minősített pontok döntő része az úgynevezett hamis pozitív döntés eredménye, nem fal pont, de az osztályozás annak minősítette.


3.3. Csoportképzés

A szemantikus szegmentáció második lépését az egymás közelébe eső, a tető osztályba tartozó pontok csoportosításával kezdjük. A DBSCAN (Density-Based Spatial Clustering of Applications with Noise) felügyelet nélküli gépi tanítási módszert alkalmazzuk a csoportok kialakítására. Ennek előnyös tulajdonsága, hogy nem kell előre ismerni a létrehozandó csoportok számát és zajszűrésre is alkalmas. A csoportosítás 45 tetőszegmenst talált, a [5] tanulmányban ugyanezen a területen 84 épületet értékelt ki manuálisan. Az 5 ábrán látható összevetésből látható, hogy ez a különbség csak négy nem felismert épületet takar, mivel a csoportosítás nem képes az összeépített épületek szétválasztására. Az ábrán lila körvonallal ábrázoltuk a manuális feldolgozásból származó épületeket.




5. ábra Tető szegmensek összehasonlítása a digitális állománnyal (random forest)

Ezután a fal pontokat szűrjük, csak a csoportosítással kialakított tető pontcsoportok körvonalán belül eső falpontokat őrizzük meg. Ebben a lépésben kétféle épületekre leszűkített pontfelhő állományokat állítunk elő épületenként, amely a tető és fal pontokat együtt illetve csak a fal pontokat tartalmazza. Az első állomány azok számára megfelelő, akik 3D épület modellek előállítását célozzák meg, a második pedig azoknak, akik az épületek 2D térképezésével foglalkoznak. A 6. ábrán a szegmentált fal pontokat mutatjuk be. Látható, hogy sok helyen hiányos az eredmény, ennek egyik oka, hogy a ferde tengelyű felvételek csak egy irányból készültek el.



6. ábra Tető poligonokkal szűrt fal szegmensek, felülnézet (random forest)



7. ábra Önálló épület modellek pontfelhői (random forest)

A fal illetve épület szegmensek alapján, az ortofotó segítségével, kis méretű (épületenkénti) pontfelhők alapján hatékonyan élvégezhető az épületek digitalizálása kisebb teljesítményű számítógépeken is, olyan térinformatikai programmal, mint például a QGIS, mely támogatja a 2D-s térkép és 3D pontfelhő megjelenítését is.

4. ÖSSZEFOGLALÁS

A cikkben bemutatott eljárás egy kutatás munkaközi eredménye. Az már most is látható, hogy a random forest illetve a neurális háló jól alkalmazható a pontfelhők pontjainak osztályozására, de más kiegészítő eljárásokra van szükség, hogy az épület objektumokat automatizáltan azonosítani tudjuk. Számos területen látunk még fejlesztési lehetőségeket. Kezdve a tanító adatok javításával és azok körének bővítésével. Emellett újabb vagy más módosított jellemzők felhasználása is szóba jöhet. Például a képfeldolgozásban gyakran alkalmazzák az RGB színek helyett a HSV (Hue/árnyalat, Saturation/telítettség, Value/fényesség) értékeket. A HSV értékek esetén az egymás közelében lévő színárnyalatok kódja is közel vannak egymáshoz, ami nem mondható el az RGB kódokról, ez megkönnyítheti az algoritmus számára az osztályozást. A random forest eljárás működését, eredményét számos úgynevezett hiperparaméterrel szabályozhatjuk, ezek finomhangolásában látunk még javítási lehetőséget, hogy a hamis pozitív tető illetve fal pontok számát csökkentjük. A neurális hálózattal osztályozás esetén a rejtett rétegek száma illetve a neuronok száma tuningolható. További lehetőségeket látunk a túl- és alul-tanítás lehetőségeinek korlátozására.

KÖSZÖNETNYILVÁNÍTÁS

A kutatás a 2022-2.1.1-NL-2022-00012 számú "Koooperatív Technológiák Nemzeti Laboratórium" projekt a Kulturális és Innovációs Minisztérium Nemzeti Kutatási és Fejlesztési és Innovációs Alapból nyújtott támogatásával, a Nemzeti Laboratóriumok pályázati program finanszírozásában valósult meg.

Köszönjük minden általunk felhasznált nyílt forráskódú fejlesztői közösség munkáját. A teljesség igénye nélkül, a következő programokat, program könyvtárakat használtuk: CloudCompare, Keras, Scikit-learn, Open3D, laspy, QGIS.

IRODALMI HIVATKOZÁSOK

- [1] Bonaccorso G. *Machine Learning Algorithms - Second Edition*, 2018. Packt, ISBN 9781789347999
- [2] Ditho T. P., Kurniawan A. W. *Evaluation of Cloth Simulation Filter (CSF) for Ground Filtering in UAV-Based DTM Generation to Support Urban 3D Cadastre* 2025 IOP Conf. Ser.: Earth Environ. Sci. 1551 012011
- [3] Grilli, E., Menna F., Remondino F. *A review of point clouds segmentation and classification algorithms*, The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLII-2/W3, pp. 339–344, 2017.
- [4] He G. B., Li L. L. *Research and application of lidar technology in cadastral surveying and mapping*. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLIII-B1-2020, pp. 33–37, 2020. <https://doi.org/10.5194/isprs-archives-XLIII-B1-2020-33-2020>
- [5] Holéczy E. Oláh R. Siki Z., Takács B., Tóth Z., Varga T. *Módszertani útmutató az elavult ingatlan-nyilvántartási térképek korszerű technológiákkal végzett felújításához* Magyar Mérnöki Kamara Kiadványsorozata 63., 82 p. (2020)

- [6] Hrutka B. P., Siki Z., Takács B. *VOXEL-BASED POINT CLOUD SEGMENTATION AND BUILDING DETECTION* INTERNATIONAL ARCHIVES OF THE PHOTOGRAMMETRY REMOTE SENSING AND SPATIAL INFORMATION SCIENCES 48 : 4/W1-2022 pp. 209-215. , 7 p. (2022) <https://doi.org/10.5194/isprs-archives-XLVIII-4-W1-2022-209-2022>
- [7] Hrutka B. P. *Application of Machine Learning to Detect Building Points in Photogrammetry-based Point Clouds* PERIODICA POLYTECHNICA-CIVIL ENGINEERING 68 : 4 pp. 1021-1030. , 10 p. (2024)
- [8] Kedzierski M., Fryskowska A., Wierzbicki D., Nerc P. *Chosen aspects of the production of the basic map using UAV imagery*. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLI-B1, pp. 873–877, 2016. <https://doi.org/10.5194/isprsarchives-XLI-B1-873-2016>
- [9] Kurczynski Z., Bakula K., Karabin M., Markiewicz J. S., Ostrowski W., Podlasiak P., Zawieska D. *The Possibility of Using Images Obtained from the UAS in Cadastral Works*. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XLI-B1, pp. 909–915, 2016. <https://doi.org/10.5194/isprsarchives-XLI-B1-909-2016>
- [10] Li M., Rottensteiner F., Heipke C. *Modelling of buildings from aerial LiDAR point clouds using TINs and label maps*, ISPRS Journal of Photogrammetry and Remote Sensing, Volume 154, 2019, Pages 127-138, ISSN 0924-2716, <https://doi.org/10.1016/j.isprsjprs.2019.06.003>
- [11] Rijdsdijk M., van Hinsbergh W. H. M., Witteveen W., tenBuuren G. H. M., Schakelaar G. A., Poppinga G., van Persie M., Ladiges R. *Unmanned Aerial Systems in the Process of Juridical Verification of Cadastral Border*. The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, XL-1/W2, pp. 325–331, 2013. <https://doi.org/10.5194/isprsarchives-xl-1-w2-325-2013>
- [12] Šafář V., Potůčková M., Karas, J., Tlustý J., Štefanová E., Jančovič M., Žofková D. C. *The use of UAV in Cadastral mapping of the Czech Republic*. ISPRS International Journal of Geo-Information, 10(6), 380, 2021. <https://doi.org/10.3390/ijgi10060380>
- [13] 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>