

Háromdimenziós környezetértelmezés mobil lézerszkenneléses adaton

Ph.D. disszertáció tézisei

Nagy Balázs
mérnökinformatikus

Tudományos vezető:
Dr. Benedek Csaba



Pázmány Péter Katolikus Egyetem
Információs Technológiai és Bionikai Kar

Budapest, 2020

1. Bevezetés

Az utóbbi évtizedekben a távérzékelő szenzorok és a különféle térképező rendszerek hatalmas fejlődésen mentek keresztül és ez új távlatokat nyitott az olyan környezetérzékeléssel foglalkozó tudományos kutatások körében, mint például az objektumdetekció és -klasszifikáció. Ezzel párhuzamosan, a grafikus processzorok teljesítményének nagyfokú növekedése, lehetővé tette a különféle mélytanuló alapú eljárások széleskörű elterjedését. Ezeket a mélytanuló eljárásokat arra fejlesztették ki, hogy olyan releváns jellemzőket nyerjenek ki az adatbázisokból a tanulási folyamat során, amelyek nagyfokú általánosítást tesznek lehetővé. Napjainkban a legtöbb releváns, számítógépes látás körébe tartozó probléma megoldására létezik egy olyan mélytanuló hálózat, amely egyre jobban megközelíti vagy akár túl is teljesíti az emberi teljesítmény pontosságát. Azonban ezen modellek tanításához nagyméretű, címkézett adatbázisok szükségesek, melyek előállítása nagyon erőforrás- és időigényes feladat, továbbá az olyan kihívásokkal teli helyzetekben, mint például a sűrű városi környezetben való navigálás, feltérképezetlen területen való tájékozódás, vagy a rossz időjárás és fényviszonyok melletti működés, még mindig sokszor alulteljesítenek.


A szenzorfüzió, azaz egyszerre több, akár különféle szenzor együttes használata egy döntés meghozatalában nagyban növelheti a különféle algoritmusok megbízhatóságát és pontosságát, még olyan extrém körülmények között is, mint a heves esőzések és rossz látási viszonyok. Napjainkban, a pontosabb környezetértelmezés és lokalizáció elérése érdekében a különféle nagy felbontású (HD) térképek és földrajzi információs rendszerek (GIS) adatainak felhasználása és értelmezése is fontos kutatási irányvá vált. Az adatfüzióra, a fedélzeti érzékelő szenzorok adatai és az offline részletes térkép-adatbázisok között számos ipari projektben támaszkodnak, például a *Waymo* és az *Uber* önjáró járművek esetében is. Az intelligens városok széleskörű elterjedésével, az önjáró járművek felhasználhatják a statikus háttérinformációkat a navigációhoz, a lokalizációhoz és a környezet kontextuális alapú elemzéséhez, azáltal, hogy a valós időben rögzített szenzoradataikat hozzá regisztrálják a részletes térkép

megfelelő részéhez. Habár a HD térképek megkönnyítik a lokalizációt és a környezetértelmezést, a dinamikus objektumok (például *járművek* és *gyalogosok*) jelenléte és a folyamatosan változó forgalmi szituációk továbbra is valós idejű környezetérzékelést igényelnek.

Míg az optikai kamerák nagy felbontású, színes, részletgazdag információt képesek rögzíteni, addig a valós idejű Lidar szenzorok, mint pl. a Velodyne HDL-64E pontos 3D geometriai információt biztosítanak a környezetükről, akár 100 méter távolságig. A Lidar távérzékelő szenzorok előnye, hogy a fényviszonyok és a különféle időjárási tényezők kisebb hatással vannak a rögzített adatokra, mint a kamerák esetében. Ezért elengedhetetlen a különféle érzékelők együttes használata, pl. a kamera és a Lidar szenzorok közötti kalibrálás a pontosabb és megbízhatóbb környezetértelmezés érdekében. A disszertáció új megközelítéseket javasol három kutatási problémára vonatkozóan: Az első feladat egy automatikus szegmentálás, azaz sűrű pontfelhők címkézése, amelyet egy mobil térképező rendszer rögzített városi környezetben. A második megvizsgált probléma új megoldást ajánl robusztus, valós idejű regisztrációhoz különféle típusú pontfelhők között, és javaslatot tesz egy módszerre az önjáró járművek lokalizációs problémájának megoldására azáltal, hogy a valós időben rögzített pontfelhő adatokat hozzáilleszti egy szegmentált, sűrű pontfelhő térképhez. Az utoljára bemutatott feladat egy automatikus kamera és Lidar alapú szenzorfüziós eljárás, amely menet közben képes a szenzorokat kalibrálni.

2. Új tudományos eredmények

1. tézis: Egy új pontfelhőszegmentáló modellt javasoltam, amely képes városi környezetben rögzített sűrű 3D pontfelhőket szemantikailag megcímkézni. Ajánlottam egy pontfelhőregisztrációs eljárást, amely a szemantikailag címkézett sűrű pontfelhő és az önjáró járművek valós időben rögzített Lidar adatai alapján képes a jármű pontos lokalizációjára. Kvantitatív módon összehasonlítottam és kiértékeltem a javasolt megközelítéseket nyilvánosan elérhető



1. ábra. Az ajánlott pontfelhő szegmentációs módszer eredménye [1. Tézis].

adatbázisokon a legkorszerűbb módszerekkel szemben.

A szerző kapcsolódó publikációi: [2][8][9][10]

A javasolt pontfelhőszegmentációs módszer célja, hogy egy mobil térképező rendszer, például a Riegl VMX-450 által rögzített sűrű pontfelhő minden egyes pontjához egy címkét rendeljen különböző szemantikai kategóriák közül. A Riegl VMX-450 a szkennelés során beérkező pontfelhőrészeket egy közös koordinátarendszerbe transzformálja és georeferálja azokat. Így a pontfelhő rögzítése során a szkennelő platformmal egyidejűleg mozgó dinamikus objektumok (*járművek* és *gyalogosok*) egy elnyújt, zajos, régióként fognak megjelenni, amelyekre *fantomobjektumokként* hivatkozok a disszertációban. A letapogatási folyamat során egyes területeket a szenzor többször is rögzített így inhomogén pontsűrűségű adat keletkezik. Habár a térképező rendszer egy kalibrált kamera platform segítségével

gével színinformációt rendel a rögzített 3D pontokhoz, a számos takarási jelenség vagy a rossz fényviszonyok miatt ez az információ gyakran megbízhatatlan.

A javasolt modell hatékonyan képes a városi környezetben rögzített sűrű pontfelhők robusztus szegmentálására, és kísérleteink szerint a modell alkalmazható különböző adatkarakterisztikákkal rendelkező pontfelhők szegmentálására is. A szegmentált sűrű pontfelhő egy lehetséges felhasználási módjára egy valós idejű lokalizációs algoritmust javasoltam, amely képes az önjáró jármű valós időben rögzített Lidar adatait a sűrű georeferált pontfelhőhöz regisztrálni.

1.1. Egy kétsatornás voxel tömb alapú reprezentációját hoztam létre a pontfelhőnek, ahol minden egyes voxelhez hozzárendeltem a lokális pontfelhő sűrűséget és az adott magasság értékeket. Megmutattam, hogy a javasolt voxelizált adattömb egy jó leíró kompakt reprezentációja a pontfelhőnek, amely felhasználható a CNN architektúrák közvetlen bemeneteként. A javasolt megközelítés kísérleti validálására és a bevezetett voxel adatok reprezentációs előnyeinek bemutatására létrehoztam egy új, mobil lézerszkenneléses méréseket tartalmazó, pontszinten annotált (MLS) adatbázist, és nyilvánosan elérhetővé tettem azt.

Habár számos pontfelhőszegmentálási megközelítés létezik a szakirodalomban [14, 15, 16, 17], ezek többsége gyengén teljesít inhomogén pontsűrűség esetén és nem veszik figyelembe az adott pontfelhő szegmensek globális elhelyezkedését, azaz független, lokális tanító mintaként értelmezik azokat. A javasolt módszer a voxelreprezentáció előállításánál minden egyes voxelhez hozzárendeli az adott pontfelhő részlet sűrűség értékét és a talajtól számított magasságát, melyekre első és második csatornaként hivatkozok a disszertációban. Megmutattam, hogy a kétsatornás voxelizált adatstruktúra a nyers pontfelhő kompakt ábrázolása, és hatékonyan tanulható CNN architektúrák segítségével. Implementáltam egy hatékony pontfelhőannotáló keretrendszert és a mélytanuló hálózatok tanításához és teszteléséhez egy nagy pontfelhő szegmentációs adatbázist hoz-

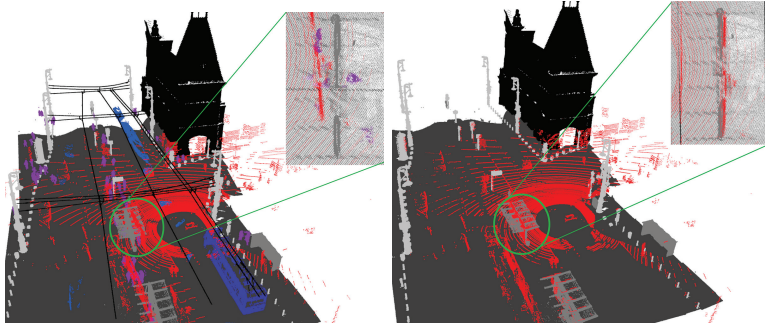
tam létre manuális címkézés segítségével, ami több mint 500 millió pontot tartalmaz. Az adatbázist nyilvánosan elérhetővé tettem (<http://mplab.sztaki.hu/geocomp/SZTAKI-CityMLS-DB.html>).

1.2. A 3D pontfelhő adatainak szegmentálására egy új LeNet stílusú 3D CNN architektúrát javasoltam, amely hatékonyan képes megtanulni az előző tézisben javasolt 2-csatornás voxelizált adatstruktúrát. A javasolt módszer pontosságát az általam manuálisan címkézett adatokon és nyilvánosan elérhető adatbázisokon is kiértékeltem. Megmutattam a javasolt megközelítés előnyeit az utóbbi öt évben publikált legsikeresebb, hasonló feladatra alkalmazható mélytanuló eljárásokkal szemben.

Javasoltam egy új 3D konvolúciós neurális hálózatot, amely hatékonyan képes különféle jellemzők kinyerésére sűrű MLS pontfelhők-ből származtatott 2-csatornás voxelizált adatstruktúrából. Kvantitatív módon kiértékeltem a módszert és megmutattam, hogy a pontsűrűség és globális elhelyezkedés figyelembevételével az ajánlott módszer jobb eredményt képes elérni inhomogén pontfelhő szegmentációs feladatokban más szakirodalmi modelleknél.

1.3. Kifejlesztettem egy új, valós idejű pontfelhő regisztrációs módszert, ami hatékonyan képes különböző sűrűség karakterisztikával rendelkező pontfelhőket regisztrálni. A javasolt regisztrációs módszer alapján kidolgoztam egy lokalizációs eljárást, amely valós időben rögzített Lidar adatokat képes nagy pontossággal hozzárendelni egy sűrű, szegmentált pontfelhő megfelelő részeihez. A javasolt módszert változatos városi szituációkat tartalmazó adathalmazon értékeltem ki.

A jelerősség ingadozása miatt a GPS-alapú lokalizáció gyakran megbízhatatlan. Kísérleteink alapján a GPS alapú helyzetmeghatározás hibája 10 méternél is nagyobb lehet sűrű városi környezetben, mint például Budapest utcáin. A lokalizációs probléma megoldására egy objektum alapú előigazítási módszert javasoltam, ami a Lidar adatokat egy sűrű georeferált pontfelhőhöz regisztrálja, majd megmutattam, hogy egy pontszintű regisztrációs algoritmussal az ered-



(a) Lokalizációs eredmény [8] az eredeti pontfelhő alapján.

(b) Lokalizációs eredmény [8], az ajánlott CNN módszerrel megtisztított pontfelhőn.

2. ábra. A javasolt CNN osztályozási módszer alkalmazása a pontfelhő regisztrációjának javítására. Ritka Lidar pontfelhő automatikus regisztrációjának eredményei (minden képen piros színűek) a sűrű MLS mérésekhez (fennmaradó színek). Az a) ábra a regisztráció eredményét mutatja a fantomobjektumokat tartalmazó pontfelhőn, jelentős pontatlanságokkal (az MLS pontfelhő különböző színei csak a jobb láthatóságot szolgálják). A (b) ábra bemutatja a sikeres regisztráció eredményét, amely a dinamikus objektumok eltávolításának köszönhető.

mény tovább finomítható. Az objektum alapú előigazítás megbízhatóbbá tételéhez javasoltam egy új kulcspontkinyerő módszert, amely képes robusztus regisztrációs kulcspontokat detektálni 3D pontfelhő szegmensekből. Kísérleti úton megmutattam, hogy a javasolt előigazítási módszer 0.4 méteres hibahatár alá képes csökkenteni a GPS-mérés pozicionálási hibáját, ami jelentős javulást jelent a kezdeti 10 méteres hibához képest.

2. tézis: Javasoltam egy automatikus, kalibrációs objektum nélkül működő kamera-Lidar külső paraméter-kalibrálási módszert, és megmutattam a módszer előnyeit a jelenlegi legkorszerűbb szakirodalmi algoritmusokkal szemben.

A szerző kapcsolódó publikációi: [1][5][7]

A javasolt módszer fő célja kamera és Lidar szenzorok automatikus kalibrálása, melyek egy mozgó jármű tetején helyezkednek el. A javasolt módszer az elejétől a végéig automatikusan működik, bármiféle felhasználói beavatkozás nélkül, és nem igényel különleges kalibrációs objektumokat, mint például 3D dobozokat és sakktabla mintákat. A módszer fő előnye, hogy képes menet közben periodikusan újra kalibrálni a szenzorokat, a jármű megállítása nélkül.

2.1. A kamera-Lidar kalibrálási feladatot egy a Lidar szenzor által rögzített pontfelhő és a beérkező kameraképekből egy Structure from Motion (SfM) algoritmus alapján létrehozott pontfelhő regisztrálási feladatként definiáltam újra.

Releváns jellemzőmegfeleltetések kinyerése különböző 2D és 3D adatok között nagy kihívást jelent és gyakran nem megbízható. Ezért javasoltam egy Structure from Motion alapú eljárást, amely az egymás után beérkező kameraképekből 3D pontfelhőt képes létrehozni és a kamera-Lidar kalibrációs problémát egy 3D pontfelhőregisztrációs feladatként értelmeztem újra. A javasolt módszer a Lidar által rögzített pontfelhőt az SfM pontfelhő koordináta rendszerébe transzformálja: első lépésben egy objektum alapú előillesztést hajt végre a módszer, majd egy görbe alapú finomítás segítségével pon-



3. ábra. A javasolt kamera-Lidar kalibrációs eljárás eredménye [1].

tosítja a regisztrációt.

2.2. Javasoltam egy robusztus objektum-alapú regisztrációs algoritmust a 3D Lidar pontfelhő és a generált SfM pontfelhő adatok között, és objektumszűrési módszereket ajánlottam a regisztráció robusztusabbá tétele érdekében.

Módosítottam az 1. tézisben javasolt objektum-alapú előigazítási eljárást [8], továbbá ajánlottam két mélytanuló hálózat alapú módszert a pontfelhőkben fellelhető dinamikus objektumrégiók kiszűrésére, amely hatására a regisztráció nagy mértékben robusztusabbá vált. A regisztráció során a statikus utcai objektumokra támaszkodtam, mint például az *oszlopok*, *közlekedési táblák* és *fatörzsek*. A javasolt módszer a mélytanulás alapú objektumszűrés segítségével elemezni képes az adott jelenet, és csak akkor kezd új kalibrálást, ha megfelelő számú statikus objektumot érzékel az adott jelenetben.

2.3. Javasoltam egy kontroll görbe alapú pontfelhő regisztráció finomító eljárást, amely képes az SfM pontfelhő lokális deformációjának kiküszöbölésére.

Az SfM módszer során lokális pontfelhő-deformációk és méretezési hibák fordulhatnak elő, amelyek nagy hatással lehetnek a regisztráció folyamatára, ezért egy kontroll görbe alapú algoritmust

javasoltam ezeknek a hibáknak a kiküszöbölésére. Az előigazítási folyamatban kinyert statikus objektumok alapján egy NURBS-görbét illesztettem mind a Lidar, mind az SfM pontfelhőre. A vezérlőgörbék leírják a pontfelhők alakját és torzulásait. Javasoltam egy algoritmust, amely képes a két görbe szegmenseit egy nemlineáris transzformációval egymáshoz igazítani, azaz a Lidar pontfelhőt az SfM pontfelhő alakja szerint deformálni. A kontrol görbe alapú finomítás alkalmazásával a módszer képes pontosan regisztrálni a pontfelhőket, és kiszámítani a megfelelő transzformációs mátrixot, amely a 3D Lidar pontokat a megfelelő 2D képpontokra vetíti.

Egy 10 kilométer hosszú útszakaszt tartalmazó adatbázison kvantitatív módon kiértékeltem és összehasonlítottam a javasolt kalibrációs technikát a legkorszerűbb referencia módszerekkel. A kiértékeléshez 200 különféle teszt helyszínt választottam, melyek tartalmaztak *főutakat, szűk mellékutakat, és útkereszteződéseket*. Megmutattam, hogy a javasolt módszer versenyképes alternatívát jelent a különböző automatikus kamera-Lidar kalibrációs technikákkal szemben és egyes esetekben a módszer pontossága képes elérni az offline, kalibrációs eszközt alkalmazó módszerek pontosságát is.

3. Az eredmények alkalmazási területei

A disszertációban tárgyalt módszerek alkalmazhatóak lehetnek különböző korszerű gépi látásfunkciókkal rendelkező rendszerekben, pl. önjáró járművek környezetérzékelésénél. A disszertációban bemutatott eljárások közül több is szorosan kapcsolódik a SZTAKI és PPKE részvételével az elmúlt években folyó kutatási projektekhez. A bemutatott objektum detektációs módszert egy valós idejű rendszerbe építettük be, amit a Kutatók éjszakáján, a Magyar Ipar Napja konferencián és a 2017-es Frankfurti autósalonon (IAA) is bemutattunk, ahol a Velodyne Lidar szenzorgyártó céggel közösen demonstráltuk a rendszer működését.

4. Adatbázisok és implementációs részletek

Mélytanuló eljárások tanításához és teszteléséhez létrehoztam egy nagyméretű pontfelhő adatbázist *SZTAKI CityMLS* néven, amelyet nyilvánosan elérhetővé tettem. A javasolt pontfelhőszegmántáló modell alkalmazhatóságát a *Oakland*, *Paris-rue-Madame* és *TerraMobilita* publikusan elérhető adatbázisokon is teszteltem. Ezek a referenciaadatbázisok nagymértékben eltérő pontsűrűségkarakterisztikát mutatnak a bemutatott *SZTAKI CityMLS* adatbázishoz képest, továbbá az általam publikált adatbázis körülbelül egy nagyságrenddel több pontot tartalmaz.

A kamera-Lidar kalibrációs algoritmus kiértékeléséhez 200 különböző helyszínt választottam egy 10 kilométer hosszú útszakaszt tartalmazó adatbázisból. Minden egyes helyszínhez tartozott egy kamera kép és a hozzá tartozó Lidar pontfelhő, és egy referencia kalibráció.

A tézisben bemutatott algoritmusok és a vizualizációs keretrendszer nagyrésze a C/C++ és az OpenGL nyelvek segítségével készült. A mélytanuló eljárásokat Python3 nyelven a TensorFlow matematikai könyvtár segítségével implementáltam. A hálózatok tanításához két Nvidia Geforce RTX 2080 Ti GPU-t használtam, melyhez 2×11 GB eszközmemória és 64 GB fő memória állt rendelkezésre.

5. Köszönetnyilvánítás

Mindenekelőtt őszinte köszönetet szeretnék mondani Benedek Csaba témavezetőmnek a doktori tanulmányaim és munkám során nyújtott folyamatos támogatásáért, motivációjáért és türelméért.

A BSc tanulmányaim óta tagja vagyok a SZTAKI Gépi Érzékelés Kutatólaboratóriumának (MPLAB), ezért külön köszönetet szeretnék mondani Szirányi Tamás professzor úrnak, aki mindig hasznos megjegyzésekkel és tanácsokkal támogatta a munkámat.

A Pázmány Péter Katolikus Egyetem (PPKE) szintén hálám illeti, köszönöm Dr. Szolgay Péter professzor úrnak, hogy lehetőséget adott nekem doktori tanulmányaim elvégzéséhez.

Köszönöm a disszertációm bírálóinak munkáját és értékes észrevételeiket.

Köszönöm a legközelebbi kollégáim sok tanácsát és segítségét a SZTAKI Gépi Érzékelés Kutatólaboratóriumából: Benedek Csaba, Manno-Kovács Andrea, Kovács Levente, Tizedes László, Majdik András és Börcs Attila. Külön köszönet Kovács Leventének és Tizedes Lászlónak, akik folyamatosan támogattak és értékes tanácsokkal láttak el a közös munkák során.

Külön köszönet Tornai Kálmánnak a PPKE-ről, aki támogatott és segített a PPKE-nél vezetett gyakorlatok során.

Köszönet a PPKE és a SZTAKI munkatársainak.

További köszönet a pénzügyi támogatásokhoz, a Nemzeti Kutatási, Fejlesztési és Innovációs Alapnak (K-120233, KH-125681 és KH-126688), az Európai Unió és a magyar kormány (EFOP-3.6.2-16-2017-00013 és a 3.6.3 VEKOP-16-2017-00002), az ÚNKP-19-3 új nemzeti kiválósági programnak.

Végül, de nem utolsósorban, szeretnék köszönetet mondani a családomnak: a szüleimnek és az öcsémnek, hogy spirituálisan támogattak engem Ph.D éveim során és úgy általában az életben.

6. Publications

6.1. The Author's Journal Publications

- [1] **B. Nagy** and C. Benedek, „On-the-fly camera and Lidar calibration,” *MDPI Remote Sensing*, 2020.
- [2] —, „3D CNN-based semantic labeling approach for mobile laser scanning data,” *IEEE Sensors Journal*, vol. 19, no. 21, pp. 10 034–10 045, 2019.
- [3] C. Benedek, B. Gálai, **B. Nagy**, and Z. Jankó, „Lidar-based gait analysis and activity recognition in a 4D surveillance system,” *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 28, no. 1, pp. 101–113, 2018.
- [4] A. Börcs, **B. Nagy**, and C. Benedek, „Instant object detection in Lidar point clouds,” *IEEE Geoscience and Remote Sensing Letters*, vol. 14, no. 7, pp. 992–996, 2017.

6.2. The author's International Conference Publications

- [5] **B. Nagy**, L. Kovács, and C. Benedek, „SFM and semantic information based online targetless camera-Lidar self-calibration,” in *2019 IEEE International Conference on Image Processing*,

- ICIP, Taipei, Taiwan, September 22-25, 2019*, 2019, pp. 1317–1321.
- [6] Y. Ibrahim, **B. Nagy**, and C. Benedek, „CNN-based watershed marker extraction for brick segmentation in masonry walls,” in *Image Analysis and Recognition - 16th International Conference, ICIAR, Waterloo, ON, Canada, August 27-29, 2019*, ser. Lecture Notes in Computer Science, vol. 11662. Springer, 2019, pp. 332–344.
- [7] **B. Nagy**, L. Kovács, and C. Benedek, „Online targetless end-to-end camera-Lidar self-calibration,” in *16th International Conference on Machine Vision Applications, MVA, Tokyo, Japan, May 27-31, 2019*. IEEE, 2019, pp. 1–6.
- [8] **B. Nagy** and C. Benedek, „Real-time point cloud alignment for vehicle localization in a high resolution 3D map,” in *Computer Vision - ECCV 2018 Workshops - Munich, Germany, September 8-14, 2018, Proceedings, Part I*, ser. Lecture Notes in Computer Science, vol. 11129. Springer, 2018, pp. 226–239.
- [9] —, „3D CNN based phantom object removing from mobile laser scanning data,” in *2017 International Joint Conference on Neural Networks, IJCNN, Anchorage, AK, USA, May 14-19, 2017*. IEEE, 2017, pp. 4429–4435.
- [10] B. Gálai, **B. Nagy**, and C. Benedek, „Crossmodal point cloud registration in the Hough space for mobile laser scanning data,” in *23rd International Conference on Pattern Recognition, ICPR, Cancún, Mexico, December 4-8, 2016*. IEEE, 2016, pp. 3374–3379.
- [11] C. Benedek, **B. Nagy**, B. Gálai, and Z. Jankó, „Lidar-based gait analysis in people tracking and 4D visualization,” in *23rd European Signal Processing Conference, EUSIPCO, Nice, France, August 31 - September 4, 2015*. IEEE, 2015, pp. 1138–1142.

- [12] A. Börcs, **B. Nagy**, M. Baticz, and C. Benedek, „A model-based approach for fast vehicle detection in continuously streamed urban Lidar point clouds,” in *Computer Vision - ACCV Workshops - Singapore, Singapore, November 1-2, 2014, Revised Selected Papers, Part I*, ser. Lecture Notes in Computer Science, vol. 9008. Springer, 2014, pp. 413–425.
- [13] A. Börcs, **B. Nagy**, and C. Benedek, „Fast 3D urban object detection on streaming point clouds,” in *Computer Vision - ECCV Workshops - Zurich, Switzerland, September 6-7 and 12, 2014, Proceedings, Part II*, ser. Lecture Notes in Computer Science, vol. 8926. Springer, 2014, pp. 628–639.

6.3. Selected Publications Connected to the Dissertation

- [14] G. Pang and U. Neumann, „3D point cloud object detection with multi-view convolutional neural network,” in *International Conference on Pattern Recognition (ICPR)*, Cancun, Mexico, 2016, pp. 585–590.
- [15] W. Wang, R. Yu, Q. Huang, and U. Neumann, „SGPN: Similarity group proposal network for 3D point cloud instance segmentation,” in *IEEE Conf. on Computer Vision and Pattern Recognition (CVPR)*, Salt Lake City, UT, June 2018, pp. 2569–2578.
- [16] J. Huang and S. You, „Point cloud labeling using 3D convolutional neural network,” in *International Conference on Pattern Recognition (ICPR)*, Cancun, Mexico, 2016, pp. 2670–2675.
- [17] C. Qi, L. Yi, H. Su, and L. J. Guibas, „Pointnet++: Deep hierarchical feature learning on point sets in a metric space,” in *Conference on Neural Information Processing Systems (NIPS)*, Long Beach, CA, USA, 2017.