

LIDAR Alapú Gépi Látás a Közlekedésben Részleges Pontfelhőkből

Rózsa Zoltán* #. Szirányi Tamás* #

*Magyar Tudományos Akadémia (MTA), Számítástechnikai és Automatizálási Kutatóintézet (SZTAKI), H-1111 (Tel: +36 1 279 6106; e-mail: sziranyi.tamas@sztaki.mta.hu; rozsa.zoltan@sztaki.mta.hu).

#Budapesti Műszaki és Gazdaságtudományi Egyetem (BME), Közlekedésmérnöki és Járműmérnöki Kar (KJK) Anyagmozgatási és Logisztikai Rendszerek Tanszék (ALRT), H-1111 (Tel: +36 1 463 1111/5741)

Az autonóm járművek 3D környezetének megismeréséhez szükséges a 3D pontfelhők feldolgozása. Ez a cikk a tárgy felismerés feladatát tárgyalja, részleges felvételek esetében. A módszerünk tovább fejleszti a 3D távérzékelővel felszerelt autonóm járművek detekcióját. Az ipari gyakorlatban az AGV-k (Automated Guided Vehicles) életvédelmi szenzorjai és a lokalizációs technológiák nyújtják az adat fúzió lehetőségét, annak érdekében, hogy a 2D-s kontúr pontokból 3D-s pontfelhőt kapjunk. Ezen adatok felhasználásával és megfelelő kiértékelő algoritmus segítségével a járművek intelligenciája nagymértékben növelhető, új szenzorok telepítése nélkül. Ebben a tanulmányban megoldást javasolunk az akadály osztályozási kérdésre részleges pontfelhők esetén, az alak modellezése nélkül. A módszert valós méréseken teszteltük.


1. BEVEZETÉS

Az intelligens járművek általában el vannak látva életvédelmi szenzorok, vagy kis látószögű 3D LIDAR-ok adataival. A 2D LIDAR-ok éppúgy, mint a 3D-s kis látószöggel kevés vertikális információt rögzítenek egy felvétellel a közeli környezetről. Ennek az adattípusnak a feldolgozására az inkrementális regisztráció nyújt lehetőséget.

Az autonóm járművek/mobil gépek mind a szenzorokat, mind az algoritmusokat tekintve jelentős mértékű fejlődést mutatnak az utóbbi időben. Az akadályok megkülönböztetése egy fejlesztési cél lehet az ipari szállítási rendszerek AGV-i számára is, az így nyert információt sok féleképpen fel lehet használni: A felismert tárgyak szolgálhatnak navigációs pontokként, vagy a megfelelő döntés meghozatalában segíthetnek biztonságot érintő helyzetekben.

Az autonóm járműveket OSH szempontok miatt biztonsági szenzorokkal szükséges felszerelni. Irodalmi áttekintés az ütközés elkerülő rendszerekről (Mukhtar, Xia, & Tang, 2015)-ben található. Az AGV-k esetében a biztonsági eszközök általában életvédelmi szenzorok, de egy vagy több normál 2D lézerskenner is telepítve van ezeken a gépeken. Hagyományosan, amikor észleltünk egy akadályt a járműnek kiadott parancsok a következők lehetnek: menj tovább, állj meg vagy kerüld ki. Ezek a döntések az akadály távolsága és statikus vagy dinamikus természete alapján születnek. Utóbbiak megkülönböztetése önmagában sem egyszerű feladat (Yu, Cai, & Duan, 2007). Egy akadály felismerés képes irányító rendszer tud javasolni kikerülési irányt (felhasználva az egyelőre nem látható kiterjedést) és a statikus/dinamikus tárgyak megkülönböztetés is robusztusabb lehet, álló emberek nem lesznek statikusként osztályozva. Emellett a részlegesen látható tárgy paraméterivel is tud számolni (méret, maximális gyorsulás, maximális sebesség,

stb.), sőt akár viselkedés előrejelzés is megvalósítható (járművek, emberek vagy állatok másképpen fognak reagálni az autonóm jármű közeledtére).



1. ábra: Döntött lézerskennernek ipari környezetben

Az irányítórendszereknek szükséges tudniuk, hogy mi található a jármű környezetében. A 3D pontfelhőkből történő felismerés egy széles körben kutatott terület, de részleges nézetre egyelőre nincsenek használható eredmények. A 3D minta felismerés egy kihívást jelentő probléma mind teljes 3D és 2.5D esetekben (Lian, és mtsai., 2015) (Pascoal, és mtsai., 2015). A legutóbbi felismerési eredmények a 75%-ot érik el a 3D Shape Categorization Benchmark adatbázison a 3D Spatial Pyramids módszerrel (Lpez-Sastre, Garca-Fuertes, Redondo-Cabrera, Acevedo-Rodríguez, & Maldonado-Bascn, 2013).

A valós körülmények között a teljes 3D szkennelés nem lehetséges, a 2.5D tárgyfelismerés pedig még a 3D-nél is nehezebb lehet.

A következőkben a tárgyfelismerés problémáját döntött LIDAR szenzorok szekvenciálisan nyert adatain fogjuk vizsgálni. AGV-k esetében, felfelé döntött szenzorok

használatosak például belógó daru horgok érzékelésére, lefelé döntöttek pedig figyelmeztethetnek kiugró dolgokra, mint polcokról kilógó tárgyak (1. ábra). Városi környezetben leggyakrabban Mobil Lézer Szkennelés (MLS) céljából használnak döntött LIDAR szenzorokat. A tárgyakat így letről-felfelé (vagy fentről-lefelé) derítjük fel. A tárgy teljes magasságát csak akkor érzékelhetnénk, ha túl közel kerülnénk az akadályhoz, vagy egyáltalán nem is láthatnánk. Természetesen, ebbe a veszélyes közelségbe nem engedhetjük a gépjeinket, ezért a döntéshozatalnak jóval korábbi fázisban kell megtörténnie, amikor még csak részleges információ áll rendelkezésre.

Ez a tanulmány azt a felismerési problémát hivatott megoldani, amikor ritka 3D pontfelhők állíthatók össze szekvenciálisan szkennelt adatokból, anélkül, hogy teljes 3D-t kapnánk. Be fogjuk mutatni, hogy ez az adattípus elég információt tartalmazhat a jármű környezetének szemantikus szintű elemzéséhez. A mi módszerünk képes a 3D alakfelismerésre, anélkül, hogy a teljes méret látható lenne, vagy elég sűrű pontfelhő állna rendelkezésre a megfelelő alak, vagy részlet modellezéséhez. Egy tárgy felé közeledve az algoritmus összegyűjti az információt, hogy növekvő valószínűséggel ismerje fel a lehetséges tárgyat. A következőkben áttekintjük a kapcsolódó irodalmakat.

2. IRODALMI ÁTTEKINTÉS

A 3D tárgy felismerés számos különböző tudomány területen kutatott (orvostudomány (Atmosukarto, Wilamowska, Heike, & Shapiro, 2010), kiterjesztett valóság (Lee, Park, & Woo, 2011)), ezek közül is kiemelkedő jelentőséggel bír a mobil robotika, közlekedés- és járműtudományok területein (Moon, Kim, & Kim, 2007). Az alakfelismerés a megfigyeléshez és az autonóm vezetéshez elengedhetetlen. A hagyományos közlekedési rendszereket intelligensé teszi. Az alábbi pontfelhő típusokat szükséges megkülönböztetni:

- Teljes 3D: a teljes 3D felszín ismert.
- 3D: a teljes 3D felszín nem ismert, de (egynézetből) rejtett pontok igen.
- 2.5D: csak egy nézőpontból látható pontokat ismerünk (3D LIDAR).
- 2D: síkbeli körvonal pontok (2D LIDAR).
- részleges pontfelhő: regisztrált pontfelhőket jelent, így 3D-ben van, de általában kevesebb információt tartalmaz, mint a 2.5D

2.1 Szenzorok és adatszerkezet

A környezetünk 3D rekonstrukciójához különböző mélység szenzorok használhatók (kinect, ToF kamera, sztereo kamerapár) vagy módszerek, amelyek 3D információt állítanak elő 2D szenzorok segítségével (SfM). A járművek általában LIDAR szenzorral vannak felszerelve széles horizontális látószöge és a fényviszonyokra való érzéketlensége miatt.

3D LIDAR-okat gyakran használnak különböző közlekedéssel kapcsolatos alkalmazásra, pl. (Benedek, Molnár, & Szirányi, 2013)-ben forgalommonitorozási célra.

Ezekből rögtön 2.5D pontfelhőt kapunk, így az adatok feldolgozása valós időben, regisztráció nélkül történik, de függőleges felbontás és információtartalom nem mindig megfelelő. Ezzel szemben a 2D LIDAR-ok és pozíció szenzorok adatfúziója még mindig relatív olcsó és pontos megoldás a 3D rekonstrukcióra (Llamazares, és mtsai., 2012). AGV-k esetében ez különös igaz, ugyanis a szükséges szenzorok már megtalálhatók a gép fedélzetén.

2D LIDAR-okat is gyakran alkalmaznak különböző mobil robotikai feladatokra, mint SLAM (Simultaneous Localization and Mapping) (Trevor, Rogers, & Christensen, 2012), detekció és követés (Taipalus & Ahtiainen, 2011). Néhány esetben előfordul, hogy a 2D lézerszenzoreket önmagukban alkalmazzák ezekre a feladatokra. (X. Shao, Nakamura, Katabira, Shibasaki, & Nakagawa, 2007) gyalogosokat detektált térbeli és időbeli gyaloglási mintákat felhasználva. Azonban sokkal gyakoribb, hogy ezek a szenzorok csak elemei egy kiterjedt szenzor hálózatnak (Shi, és mtsai., 2015), de legalábbis egy pozíció szenzorral párosítva vannak a 3D rekonstrukció érdekében (Alvarez-Santos, Canedo-Rodriguez, R. Iglesias, Regueiro, & Fernandez-Delgado, 2015).

2.2 Tárgyfelismerés pontfelhőkből

Mind a teljes 3D, 3D és a 2.5D alakfelismerő rendszerek is lokális vagy globális alakleírókra épülnek A lokális leírók (pl.: (Li & Guskov, 2005)) egy felszín darabot jellemeznek egy adott pont körül. Az összetartozó felszín darabok megkeresése lehet az alapja a lokális leírókra alapuló tárgy felismerésnek. Ehhez szükségesek még különböző hipotézisgeneráló és verifikációs módszerek, amikről (Guo, Bennamoun, Soheli, Lu, & Wan, 2014) ad áttekintést. Ez azonban kimerítő kereséssel jár. Ezzel szemben a globális leírók egy nagyobb pontcsoportot jellemeznek jól, így elsősorban teljes 3D-s esetben használatosak tárgy és kategória felismerésre. Vannak globális leírók, amelyek alkalmazhatóak 2.5D-s esetben (Madry, Ek, Detry, Hang, & Kragic, 2012), és a legtöbb lokális leíró kiterjeszhető globálissá, ha az egész pontfelhőt egy pont szomszédságként vizsgáljuk (Rusu, Bradski, Thibaux, & Hsu, 2010).

Megoldások, amelyek a teljes tárgy ismeretére épülnek nem, vagy nem közvetlenül alkalmazhatók a mi problémánkra. A (Choe, Ahn, & Chung, 2014) szerzői GMM-et (Gaussian Mixture Model) használnak az alak leírására, (Aijazi, Serna, Marcotegui, Checchin, & Trassoudaine, 2016)-ben pedig olyan geometriai tulajdonságokat nyernek ki, mint alak, méret, súlypont. Ezek nem határozhatók meg részleges pontfelhőkből.

A nem regisztrált 2D pontfelhőkből való klasszifikáció nehezen megvalósítható, ugyanis hiányzik a felület információ, és így a megkülönböztető tulajdonságok. Ezt a hiányzó információt vizuális információval próbálták helyettesíteni (Lee, Hur, & Park, 2015). Azonban ennél a megoldásnál hatékonyabb a pontfelhők regisztrálása.

3. A MÓDSZER

A javasolt módszer lokális minták statisztikáit hasonlítja össze. A következő lépésekből áll: Első lépésben egy lokális

felületet definiálunk minden pont környezetében, majd kulcspontokat keresünk a Harris operátor (Sipiran & Bustos, 2011) segítségével ezen a felületen. Lokális skálát rendelünk a jelentős pontokhoz, ami meg fogja határozni a kulcspontok végső számát. Különböző kulcsponttípusok fogják kialakítani a lokális mintákat, így lokális leírók alapján osztályozzuk a kulcspontokhoz tartozó felület darabokat. Végül a különböző minták gyakoriságát hasonlítjuk össze. A módszer egy fajta BoF (Bag of Features) (Csurka, Dance, Fan, Willamowski, & Bray, 2004) megközelítés, így BoG-nak (Bag of Graphs) hívjuk. Ebben a fejezetben ismertetjük a lépéseit részletesebben.

3.1 Kulcspontkeresés és lokális felület definíció

A felhő minden pontjában a lokális felületet egy r sugárnál közelebb eső pontokkal reprezentáljuk. Erre a környezetre egy parametrikus felületet illesztünk (Sipiran & Bustos, 2011) alapján. A Harris operátor sarokszerű pontokat jelöl meg kulcspontként. A kulcspontok sűrűsége az általunk meghatározott jellemző sugár meghatározásából adódik:

$$\rho_1 = \sqrt{\frac{2}{\lambda_1}}, \quad (1)$$

ahol λ_1 a Harris mátrix kisebb sajátértéke. A gömbökön belül, amit a különböző jelentős pontokhoz tartozó ρ_1 sugarak definiálnak, csak egy kulcspont helyezkedhet el. Amikor egy kulcspontot megtaláltunk tulajdonságokat becsülünk, mint normál vektor, görbület, stb. Ezek felhasználásával kiszámítjuk az alábbi lokális leírók értékeit a pont által reprezentált felületen:

- PFH (Point Feature Histogram) α , ϕ és θ mérőszámok értékeiből létrehozott hisztogram 8 osztállyal:

$$u_p = n_s, \quad (2)$$

$$v_p = u_p \times \frac{p_t - p_s}{\|p_t - p_s\|},$$

$$w = u_p \times v_p$$

$$\alpha = w \cdot n_t,$$

$$\phi = u_p \cdot \frac{p_t - p_s}{\|p_t - p_s\|}, \quad (3)$$

$$\theta = \tan^{-1}(w \cdot n_t \cdot u_p \cdot n_t)$$

ahol, u_p , v_p és w a lokális koordináta rendszer irányvektorjai. p_t , p_s , n_t és n_s a cél és forrás pontok, és a hozzájuk tartozó normál vektorok (Rusu, Blodow, & Beetz, 2009). Ez a leíró görbület egy sűrűség invariáns általánosítása.

- Felület normális szög:

$$\cos \theta_s = \frac{n_{small} \cdot n_{large}}{\|n_{small}\| \cdot \|n_{large}\|}, \quad (4)$$

ahol n_{small} és n_{large} a normál vektorok egy kisebb és egy nagyobb szomszédsággal számolva (Flint, Dick, & Hengel, 2007). Ez a mérőszám hasznos a skálaváltás hatásának mérésére.

- Módosított shape index:

$$I_{mod} = |1/\pi \tan^{-1}(-1) [(k_11 + k_12)/(k_11 - k_12)]| \quad (5)$$

ahol $k_1 > k_2$ a fő görbületek (Zaharia & Preteux, 2001). A módosított shape index érték az eredeti [0 1] intervallumból a [0 0.5] intervallumba transzformálja az értékeket, ezzel függetlenné téve a koordináta rendszertől. A görbületek relatív orientációját és arányát tároljuk el ebben a mérőszámokban.

- Jellemző sugár a Harris fő görbületből számítva


$$\rho_2 = \sqrt{\frac{2}{\lambda_2}}, \quad (6)$$

ahol λ_2 a Harris mátrix nagyobb sajátértéke. Magas λ_1 értékekhez tartozó pontok lettek kulcspontként megjelölve, így ezekhez a pontokhoz tartozó λ_2 értékek megkülönböztető jelleggel bírhatnak.

- A lokális konvex burkoló térfogat: mind skálára, mind alakra vonatkozó információt tartalmaz.

3.2 Lokális minta definíció

A fontosnak ítélt területek rendelkezésre állnak (egy kulcsponttal és szomszédsággal képviselve). Minden egyes kulcsponthoz generálunk egy címkét a hozzátartozó leírók alapján a K-means algoritmus felhasználásával (Lloyd, 2006). Minden kulcspont körül a három legközelebbi csúcsot felhasználva definiálunk egy irányítatlan, heterogén gráfot. Ez egy rendezett 4-es $g = (V, E, \Sigma, l)$, ahol V a csúcsok (kulcspontok) halmaza, $E \subseteq V \times V$ az élek halmaza, Σ a címkék halmaza és $l: V \rightarrow \Sigma$ a függvény, ami hozzárendeli a csúcsokhoz a címkéket. A lokális minták definíciójának illusztrációja a 2. ábrán látható. Az így kialakult lokális mintákhoz még két tulajdonságot rendelünk hozzá, az egyik a középpontjuk magassága, a második pedig a gráf által kifizített térfogat.



2. ábra: Lokális minták definíciója

3.3 Klasszifikáció

Minden egyes tárgy osztály esetében megszámláljuk az előforduló minták számát. Ez lesz az adott alakhoz tartozó leíró. Nagy mintatípus szám és kisszámú előfordulás (ritka leíró) esetén alkalmazhatunk dimenziócsökkentést. A tanító objektumok BoG átlagát felhasználva klaszter középpontokat alakítunk ki minden egyes kategóriához. A teszt objektumokat pedig ehhez hasonlítjuk abszolút (L1) távolságot használva a hiba mérőszámaként. Előzetes tesztteredményeket szintetikus pontfelhőkön (Rózsa & Szirányi, 2016) tartalmaz.

4. TESZTEK VÁROSI PONTFELHŐKÖN

MLS adatokat használtunk a módszerünk valós méréseken való tesztelésére. A következő osztályok voltak a tanító és a teszt halmazokban: Fa, Autó, Oszlop, Gyalogos. A tanító szett a 3. ábrán láthatókhöz hasonló objektumokat tartalmazott.



(a) Gyalogos



(b) Fa



(c) Autó




(d) Oszlop


3. ábra: Minták a tanuló objektumokból

A teszt halmaz a tanítóhoz hasonló pontfelhőket tartalmazott. Annak érdekében, hogy részleges pontfelhőkön tesztelhesük a módszert, minden az eredeti teszt halmaz felhőből 9 újabb teszt pontfelhőt generáltunk, amivel szimuláltuk a tárgy felderítését. Minden egyes lépésben 10%-kal több a tárgy


legnagyobb kiterjedéséhez viszonyítva) látható az adott teszt tárgyból. A döntés átlagos jóságát ennek a 10 fázisnak a függvényében a 4., 5., 6. és 7. ábrákon szemléltetjük.




4. ábra: A *fa* osztály átlagos hibájának változása a különböző osztályokhoz mérve



5. ábra: Az *autó* osztály átlagos hibájának változása a különböző osztályokhoz mérve



6. ábra: Az *oszlop* osztály átlagos hibájának változása a különböző osztályokhoz mérve



7. ábra: A *gyalogos* osztály átlagos hibájának változása a különböző osztályokhoz mérve

A fenti ábrákon az első marker azt a fázist jelöli, ahol az összes teszt felhő, már megfelelő mennyiségű adatot tartalmazott a kiértékeléshez. Az alábbi következtetések vonhatók le:

- A fa osztály esetében, a kezdeti fázisokban, amíg csak a törzs látszik néhány esetben oszlopnak lett osztályozva, de amint a fa lombja megjelenik, az algoritmus egyből szét tudja a két osztályt választani.

- Az 5. fázis fölött (50 %-a látható a tárgy legnagyobb kiterjedésének, ez kb. 25 %-át jelenti a teljes objektumnak) az átlagos döntés helyes. Ez az összes osztályra nézve igaz. (Amennyiben egy gyalogosról beszélünk ez kb. 1 m magasságot jelent, vagyis alig látunk a lábai fölé.)

- A döntés jósága folyamatosan javul, ahogyan egyre többet és többet látunk egy tárgyból.

6. KONKLÚZIÓ

A tanulmányban egy módszert mutattunk be, amely a pontfelhők lokális információt használja fel. Ez a módszer képes megoldani a részleges nézetből történő részleges alakfelismerés problémáját, amit az autonóm járművek hasznosítani tudnak. Szemléltettük, hogy a módszerünk valós pont felhőkön képes megbízható döntéseket hozni. Ennek a módszernek a következő előnyei vannak a korábban LIDAR pontfelhőkön alkalmazott módszerekhez képest:

- Közvetlenül pontfelhőkön dolgozik, így a főleg, és esetleg információvesztéssel járó feldolgozási lépések (pl.: hálózás) elkerülhetők.

- Nem modell alapú, így kevésbé korlátosok a felismerhető tárgyak.

- Részleges pontfelhőkből képes felismerésre. Szegmentációs eljárásokkal párhuzamosan használva kölcsönösen segíthetik egymást.

A jövőbeli tervek között szerepel egy gyakorlati teszt rendszer kialakítása egy AGV-n.

IRODALOMJEGYZÉK

Aijazi, A. K., Serna, A., Marcotegui, B., Checchin, P., & Trassoudaine, L. (2016). Segmentation and Classification of 3D Urban Point Clouds: Comparison and Combination of Two Approaches. Cham: Springer International Publishing.

Alvarez-Santos, V., Canedo-Rodriguez, A., R. Iglesias, X. P., Regueiro, C., & Fernandez-Delgado, M. (2015). Route learning and reproduction in a tour-guide robot. *Robotics and Autonomous Systems* vol. 63, Part 2, 206 – 213.

Atmosukarto, I., Wilamowska, K., Heike, C., & Shapiro, L. G. (2010). 3D object classification using salient point patterns with application to craniofacial research. *Pattern Recognition*, vol. 43, no. 4, 1502-1507.

Benedek, C. (2014). 3D people surveillance on range data sequences of a rotating LIDAR. *Pattern Recognition Letters*, vol. 50, 149 – 158.

Choe, Y., Ahn, S., & Chung, M. J. (2014). Online urban object recognition in point clouds using consecutive point information for urban robotic missions. *Robotics and Autonomous Systems*, vol. 62, no. 8, old.: 1130-1152.

Csurka, G., Dance, C. R., Fan, L., Wilamowski, J., & Bray, C. (2004). Visual categorization with bags of keypoints

(old.: 1–22.). in *In Workshop on Statistical Learning in Computer Vision, ECCV*.

Flint, A., Dick, A., & Hengel, A. V. (2007). Thrift: Local 3D structure recognition. in *9th Biennial Conference of the Australian Pattern Recognition Society on Digital Image Computing Techniques and Applications*, (old.: 182–188).

Guo, Y., Bennamoun, M., Sohel, F., Lu, M., & Wan, J. (2014). 3D object recognition in cluttered scenes with local surface features: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 36, no. 11, 2270–2287.

Lee, M., Hur, S., & Park, Y. (2015). An obstacle classification method using multi-feature comparison based on 2D LIDAR database. in *12th International Conference on Information Technology - New Generations (ITNG)*.

Lee, W., Park, N., & Woo, W. (2011). Depth-assisted real-time 3D object detection for augmented reality. in *International Conference on Artificial Reality and Telexistence*.

Li, X., & Guskov, I. (2005). Multi-scale features for approximate alignment of point-based surfaces. in *Proceedings of the Third Eurographics Symposium on Geometry Processing*, ser. SGP '05. Aire-la-Ville, Switzerland.

Lian, Z., Zhang, J., Choi, S., ElNaghy, H., El-Sana, J., Furuya, T., . . . Wilson, R. C. (2015). Non-rigid 3D Shape Retrieval. in *Eurographics Workshop on 3D Object Retrieval*. I. Pratikakis, M. Spagnuolo, T. Theoharis, L. V. Gool, and R. Veltkamp, Eds. The Eurographics Association.

Llamazares, J., Molinos, E. J., Ocaña, M., Bergasa, L. M., Hernández, N., & Herranz, F. (2012). 3D Map Building Using a 2D Laser Scanner. Berlin: Springer.

Lloyd, S. (2006). Least squares quantization in PCM. *IEEE Trans. Inf. Theor.*, vol. 28, no. 2, 129–137.

Lpez-Sastre, R., Garca-Fuertes, A., Redondo-Cabrera, C., Acevedo-Rodriguez, F., & Maldonado-Bascn, S. (2013). Evaluating 3D spatial pyramids for classifying 3D shapes. *Computers & Graphics*, vol. 37, no. 5, 473 – 483.

Madry, M., Ek, C., Detry, R., Hang, K., & Kragic, D. (2012). Improving generalization for 3D object categorization with global structure histograms. in *2012 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)*.

Moon, H.-C., Kim, J.-H., & Kim, J.-H. (2007). Obstacle detecting system for unmanned ground vehicle using laser scanner and vision. in *International Conference on Control, Automation and Systems (ICCAS '07)*, (old.: 1758–1761).

Mukhtar, A., Xia, L., & Tang, T. B. (2015). Vehicle detection techniques for collision avoidance systems: A review. *IEEE Transactions on Intelligent Transportation Systems* vol. 16, no. 5, 2318–2338.

Pascoal, P. B., Proena, P., Gaspar, F., Dias, M. S., Teixeira, F., Ferreira, A., . . . Aono, M. (2015). Retrieval of Objects Captured with Kinect One Camera. in *Eurographics Workshop on 3D Object Retrieval*. I.

- Pratikakis, M. Spagnuolo, T. Theoharis, L. V. Gool, and R. Veltkamp, Eds. The Eurographics Association.
- Rusu, R. B., Blodow, N., & Beetz, M. (2009). Fast point feature histograms (FPFH) for 3D registration. in Proceedings of the 2009 IEEE International Conference on Robotics and Automation ICRA'09 (old.: 1848–1853). Piscataway, NJ, USA: IEEE Press.
- Rusu, R. B., Bradski, G., Thibaux, R., & Hsu, J. (2010). Fast 3D recognition and pose using the viewpoint feature histogram. in Proc. of the 23rd IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS).
- Shi, Y., Ji, S., Shao, X., Yang, P., Wu, W., Shi, Z., & Shibasaki, R. (2015). Fusion of a panoramic camera and 2D laser scanner data for constrained bundle adjustment in GPS-denied environments. *Image and Vision Computing* vol. 40, 28 – 37.
- Sipiran, I., & Bustos, B. (2011). Harris 3D: A robust extension of the Harris operator for interest point detection on 3D meshes. *Vis. Comput.*, vol. 27, no. 11, 963–976.
- Taipalus, T., & Ahtiainen, J. (2011). Human detection and tracking with knee-high mobile 2D LIDAR. in 2011 IEEE International Conference on Robotics and Biomimetics (ROBIO).
- Trevor, A. J., Rogers, J. G., & Christensen, H. I. (2012). Planar surface SLAM with 3D and 2D sensors. in 2012 IEEE International Conference on Robotics and Automation (ICRA).
- X. Shao, H. Z., Nakamura, K., Katabira, K., Shibasaki, R., & Nakagawa, Y. (2007). Detection and tracking of multiple pedestrians by using laser range scanners. in IROS 2007 IEEE/RSJ International Conference on Intelligent Robots and Systems.
- Yu, J., Cai, Z., & Duan, Z. (2007). Detection of static and dynamic obstacles based on fuzzy data association with laser scanner. in FKSD 2007 Fourth International Conference on Fuzzy Systems and Knowledge Discovery vol. 4, (old.: 172–176).
- Zaharia, T., & Preteux, F. (2001). Three-dimensional shape-based retrieval within the MPEG-7 framework. in Proceedings SPIE Conference on Nonlinear Image Processing and Pattern Analysis XII, (old.: 133–145).