

Alakfelismerés az utakon részleges pontfelhőkből

★ ★★

Rózsa Zoltán^{1,2}, Szirányi Tamás^{1,2}

¹ Magyar Tudományos Akadémia (MTA), Számítástechnikai és Automatizálási
Kutatóintézet (SZTAKI) sziranyi.tamas@sztaki.mta.hu

² Budapesti Műszaki és Gazdaságtudományi Egyetem (BME), Közlekedésmérnöki és
Járműmérnöki Kar (KJK) zoltan.rozsa@logisztika.bme.hu

Absztrakt. A 3D szenzorok képeinek, pontfelhőinek feldolgozása elengedhetetlen az autonóm járművek 3D környezetének megismeréséhez. 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 a vezető nélküli targoncák, avagy AGV-k (Automated Guided Vehicles) életvédelmi szenzorai 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 életvédelmi szenzorok, vagy kis látószögű 3D LIDAR-ok adataival ellátottak. A 2D LIDAR-ok éppúgy, mint a 3D-sek kis látószöggel kevés vertikális információt rögzítenek egy felvétellel a közeli környezetről. Ennek az adattípusnak a feldolgozására egy lehetséges megoldás az inkrementális regisztráció.

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 sokféleképpen fel lehet használni: A felismert tárgyak szolgálhatnak navigációs pontokként, vagy a megfelelő döntés meghozatalában segíthetnek biztonságot érintő helyzetekben.

Az autonóm járműveket munkavédelmi szempontok miatt biztonsági szenzorokkal szükséges felszerelni. Az ütközés elkerülő rendszerekről egy irodalmi


* Jelen cikk az [1] és az IWCIM 2016-ra (2016.10.27-28, Olaszország, Reggio Calabria) *Object detection from partial view street data* címen elfogadott publikáció eredményeit mutatja be.

** Rózsa Zoltán pályázatot nyújt be Kuba Attila díjra.

áttekintés a [2]-ben található. Az AGV-k esetében a biztonsági eszközök általában életvédelmi szenzorok, de egy vagy több normál 2D lézershíj 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 [3]. Egy akadály felismerésre képes irányító rendszer tud javasolni kikerülési irányt (felhasználva az egyelőre nem látható kiterjedést) és a statikus/dinamikus tárgy megkülönböztetés is robusztusabb lehet, álló emberek nem lesznek statikusként osztályozva. Emellett a részlegesen látható tárgy paramétereivel 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). 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 [4, 5]. A legutóbbi felismerési eredmények a 75 %-ot érik el a 3D Shape Categorization Benchmark adatbázison a 3D Spatial Pyramids módszerrel [6]. 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 (1.a ábra), lefelé döntöttek pedig figyelmeztethetnek kiugró dolgokra, mint polcokról kilógó tárgyak (1.b ábra). Városi környezetben leggyakrabban Mobil Lézershíj (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 gépeinket, 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.



1. ábra: Döntött lézerszenkerek ipari környezetben [7]

2. Irodalmi áttekintés

A 3D tárgy felismerés számos különböző tudomány területen kutatott (orvostudomány [8], kiterjesztett valóság [9]), ezek közül is kiemelkedő jelentőséggel bír a mobil robotika, közlekedés- és járműtudományok területein [10]. 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. [11]-ben forgalommonitorozási célra. Ezekből rögtön 2.5D pontfelhőt kapunk, így az adatok feldolgozása valós időben, regisztráció nélkül történik, de a függőleges irányú felbontás és az információtartalom nem mindig

megfelelő. Ezzel szemben a 2D LIDAR-ok és pozíció szenzorok adatfúziója még mindig relatív olcsó és pontos megoldás a 3D rekonstrukcióra [12]. AGV-k esetében ez különösen 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) [13], detekció és követés [14]. Néhány esetben előfordul, hogy a 2D lézerszkennereket önmagukban alkalmazzák ezekre a feladatokra. A [15] gyalogosokat detektált térbeli és időbeli gyaloglási mintákat felhasználva. Azonban sokkal gyakoribb, hogy ezek a szenzorok csak elemei egy kiterjedt szenzor hálózatnak [16], de legalábbis egy pozíció szenzorral párosítva vannak a 3D rekonstrukció érdekében [17].

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.: [18]) 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 [19] ad áttekintést. Ez azonban kimerítő kereséssel jár. Ezzel szemben a globális leírók nagyobb pontcsoportot jellemeznek jól, így elsősorban teljes 3D-s esetben használatosak tárgy és kategória felismerésre. Vannak globális leírók, amelyek alkalmazhatóak 2.5D-s esetben [20], és a legtöbb lokális leíró kiterjeszhető globálissá, ha az egész pontfelhőt egy pont szomszédságaként vizsgáljuk [21].

Megoldások, amelyek a teljes tárgy ismeretére épülnek nem, vagy nem közvetlenül alkalmazhatóak a mi problémánkra. A [22] szerzői GMM-et (Gaussian Mixture Model) használnak az alak leírására, [23]-ben pedig olyan geometriai tulajdonságokat nyernek ki, mint alak, méret, súlypont. Ezek nem határozhatóak 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 [24]. A pontfelhők regisztrálása azonban hatékonyabb ennél a megoldásnál.

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 [25] segítségével ezen a felületen. Következő lépésként lokális skálát rendelünk a jelentős pontokhoz, ami meg fogja határozni a kulcspontok végső számát. Lokális leírók alapján osztályozzuk a kulcspontokhoz tartozó felület darabokat, mivel különböző kulcsponttípusok fogják kialakítani a lokális mintákat. Végül a különböző minták gyakoriságát hasonlítjuk össze. A módszer egy fajta BoF (Bag

of Features) [26] 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 [25] 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 Harris mátrix kisebb sajátértéke. A gömbökön belül, amit a különböző jelentős pontokhoz tartozó ρ_1 sugarak definiálnak, mindösszesen 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:

$$\begin{aligned} u_p &= n_s, \\ v_p &= u_p \times \frac{p_t - p_s}{\|p_t - p_s\|}, \\ w &= u_p \times v_p, \end{aligned} \quad (2)$$

$$\begin{aligned} \alpha &= w \cdot n_t, \\ \phi &= u_p \cdot \frac{p_t - p_s}{\|p_t - p_s\|}, \\ \theta &= \arctan(w \cdot n_t, u_p \cdot n_t), \end{aligned} \quad (3)$$

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 [21]. Ez a leíró a görbület egy sűrűség invariáns általánosítása.

- Felület normális szög:

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

ahol n_{small} és n_{large} a normál vektorok egy kisebb és egy nagyobb szomszédsággal számolva [27]. Ez a mérőszám hasznos a skálaváltás hatásának mérésére.

- Módosított shape index:

$$I_{mod} = \left| \frac{1}{\pi} \arctan \frac{k_1 + k_2}{k_1 - k_2} \right|, \quad (5)$$

ahol k_1 és k_2 a fő görbületek [28]. 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 mérőszámban.

- Jellemző sugár a Harris fő görbületből számítva:

$$\rho_1 = \sqrt{\frac{2}{\lambda_1}}, \quad (6)$$

ahol λ_2 a Harris mátrix nagyobb sajátértéke. Magas λ_1 értékekhez tartozó pontok lettek kulcsponként 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 felületek rendelkezésre állnak (egy kulcsponttal és szomszédsággal képviselve). Minden egyes kulcsponthoz generálunk egy címkét a hozzátartozó leírók alapján a K-means algoritmus [29] felhasználásával. Minden kulcsponthoz a három legközelebbi csúcsot felhasználva definiálunk egy irányítatlan, heterogén gráfot. Ez egy rendezett 4-es $g = (V, E, \Sigma, l)$, ahol V a csúcsok (kulcsponthoz) 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.

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. Korábbi teszteredményeket szintetikus pontfelhőkön [1] 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,



2. ábra: Lokális minták definíciója

Gyalogos. A tanító szett a 3. ábrán láthatókhöz hasonló objektumokat tartalmazott.

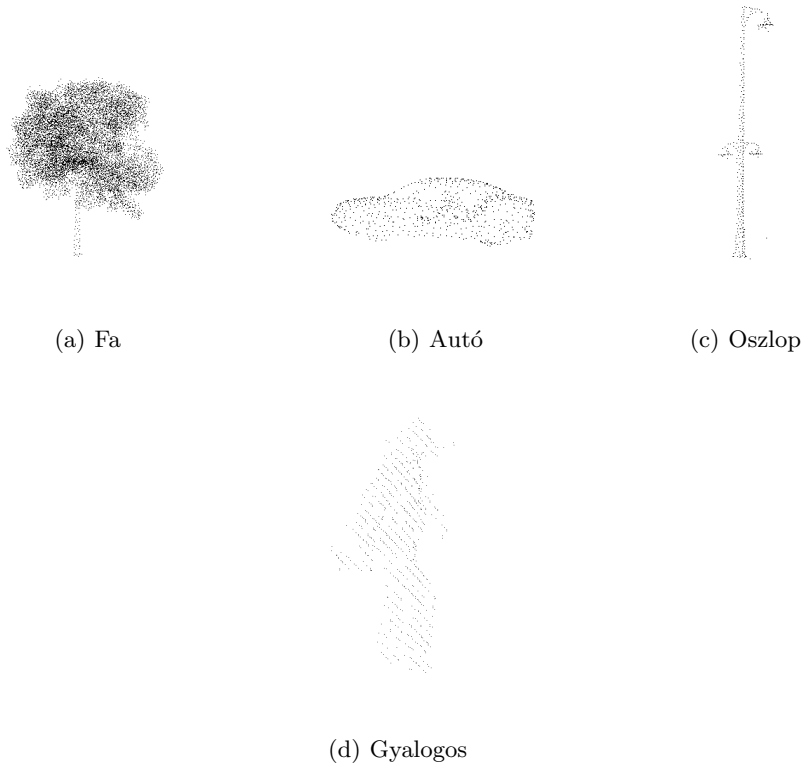
A teszt halmaz a tanítóhoz hasonló pontfelhőket tartalmazott. Annak érdekében, hogy részleges pontfelhőkön tesztelhesük a módszert, minden eredeti teszt halmaz felhőből 9 újabb teszt pontfelhőt generáltunk, így szimuláltuk a tárgy felderítését. Minden egyes lépésben 10 %-kal több (a legnagyobb kiterjedéshez viszonyítva) látható az adott teszt tárgyából. A döntés átlagos jóságát ennek a 10 fázisnak a függvényében a 4., 5., 6. és 7. ábrákon szemléltetjük.

Az 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:

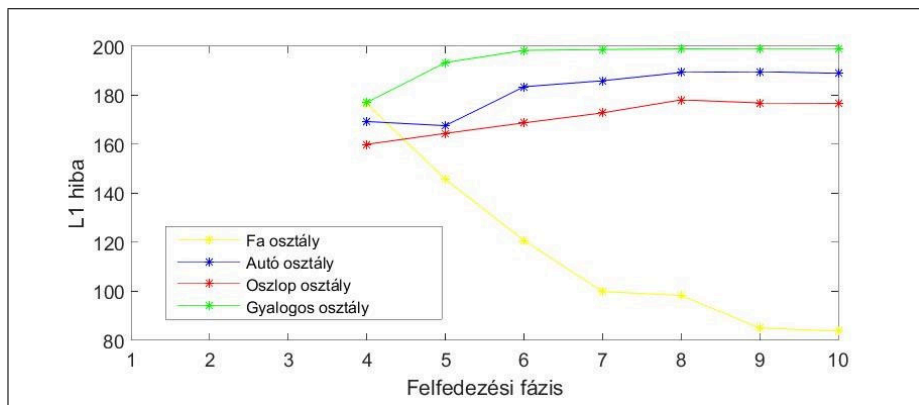
- A fa osztály esetében, a kezdeti fázisokban, amíg csak a törzs látszik néhány esetben oszlopnak lett osztályozva, de amint a fa lombja megjelenik, az algoritmus egyből szét tudja választani a két osztályt.
- Az 5. fázis fölött (50 %-a látható a tárgy legnagyobb kiterjedésének, ez kb. 25 %-át jelenti 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 tárgyából.

5. Konklúzió

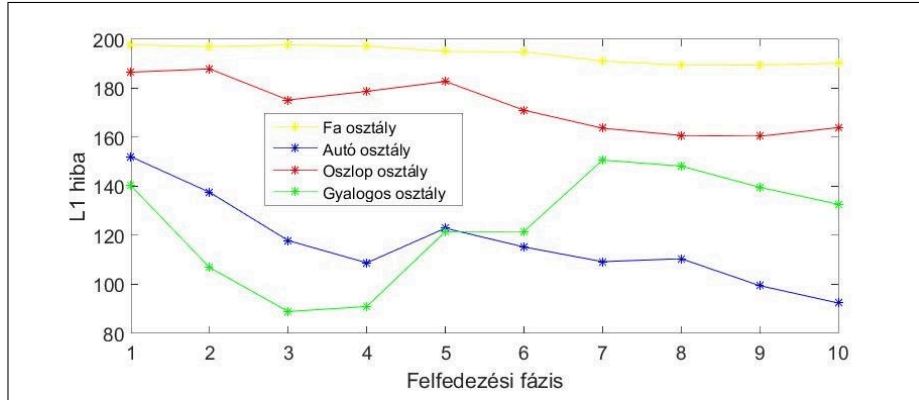
A tanulmányban egy módszert mutattunk be, amely a pontfelhők lokális információit használja fel. Ez a módszer képes megoldani a részleges nézetből történő részleges alakfelismerés problémáját, amit az autonóm járművek hasznosítani tudnak. Szemléltettük, hogy a módszerünk valós pont felhőkön




3. ábra: Minták a tanuló objektumokból



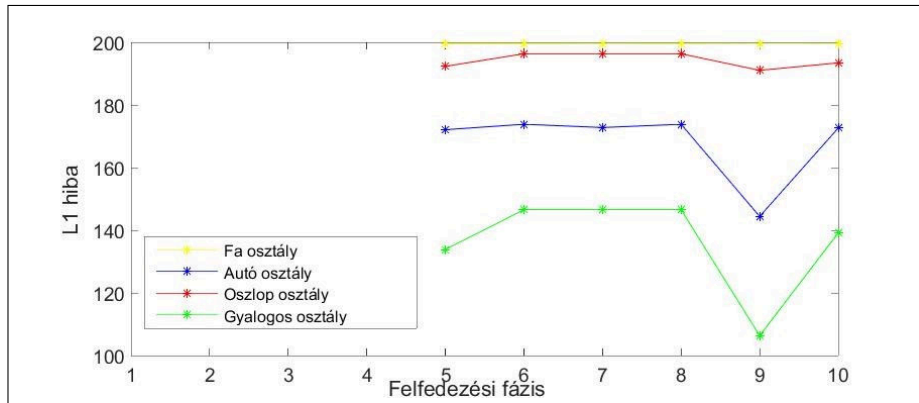
4. ábra: A *fa* osztály átlagos hibájának változása a különböző osztályokhoz mérve



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

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 korlátozott 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.

Köszönetnyilvánítás

A szerzők szeretnék megköszönni a Budapest Közút Zrt.-nek a Riegl VMX-450 Mobil Lézerszkenner adatszett biztosítását.

Irodalom

1. Rózsa Z., Szirányi T.: Exploring in partial views: Prediction of 3D shapes from partial scans. in ICCA 16. International Conference on Control and Automation (2016) 707–713
2. Mukhtar, A., Xia, L., Tang, T. B.: Vehicle Detection Techniques for Collision Avoidance Systems: A Review. IEEE Transactions on Intelligent Transportation Systems (2015) 2318–2338
3. Yu, J., Cai, Z., Duan, Z.: 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 (2007) 172–176
4. Lian, Z., Zhang, J., Choi, S., ElNaghy, H., El-Sana, J., Furuya, T., Giachetti, A., Guler, R. A., Lai, L., Li, C., Li, H., Limberger, F. A., Martin, R., Nakanishi, R. U., Neto, A. P., Nonato, L. G., Ohbuchi, R., Pevzner, K., Pickup, D., Rosin, P., Sharf, A., Sun, L., Sun, X., Tari, S., Unal, G., Wilson, R. C.: Non-rigid 3D Shape Retrieval in Eurographics Workshop on 3D Object Retrieval (2015) Pratikakis, I., Spagnuolo, M., Theoharis, T., Gool, L. V., Veltkamp, R. Eds. The Eurographics Association.
5. Pascoal, P. B., Proena, P., Gaspar, F., Dias, M. S., Teixeira, F., Ferreira, A., Seib, V., Link, N., Paulus, D., Tatsuma, A., Aono, M.: Retrieval of Objects Captured with Kinect One Camera. in Eurographics Workshop on 3D Object Retrieval (2015) Pratikakis, I., Spagnuolo, M., Theoharis, T., Gool, L. V., Veltkamp, R. Eds. The Eurographics Association.
6. Lopez-Sastre, R., Garca-Fuertes, A., Redondo-Cabrera, C., Acevedo-Rodriguez, F., Maldonado-Bascn, S.: Evaluating 3D spatial pyramids for classifying 3D shapes. Computers & Graphics, vol. 37, no. 5 (2013) 473–483
7. <https://www.sick.com>
8. Atmosukarto, I., Wilamowska, K., Heike, C., Shapiro, L. G.: 3D object classification using salient point patterns with application to craniofacial research. Pattern Recognition, vol. 43, no. 4 (2010) 1502–1517

9. Lee, W., Park, N., Woo, W. Depth-assisted real-time 3D object detection for augmented reality. in *International Conference on Artificial Reality and Telexistence* (2011)
10. Moon, H.-C., Kim, J.-H., Kim, J.-H. Obstacle detecting system for unmanned ground vehicle using laser scanner and vision. in *International Conference on Control, Automation and Systems* (2007) 17581761
11. Benedek C., Molnár D., Szirányi T.: A Dynamic MRF Model for Foreground Detection on Range Data Sequences of Rotating Multi-beam Lidar in *Advances in Depth Image Analysis and Applications: International Workshop, WDIA* (2012) 87–96
12. Llamazares, A., Molinos, E. J., Ocana, M., Bergasa, L. M., Hernandez, N., Herranz, F.: 3D Map Building Using a 2D Laser Scanner. Heidelberg: Springer Berlin Heidelberg (2012) 412–419
13. Trevor, A. J. B., Rogers, J. G., Christensen, H. I.: Planar surface SLAM with 3D and 2D sensors. in *IEEE International Conference on Robotics and Automation (ICRA)* (2012) 3041–3048
14. Taipalus, T., Ahtiainen, J.: Human detection and tracking with knee-high mobile 2D LIDAR. in *IEEE International Conference on Robotics and Biomimetics (ROBIO)* (2011) 1672–1677
15. Shao, X., Zhao, H., Nakamura, K., Katabira, K., Shibasaki, R., Nakagawa, Y.: Detection and tracking of multiple pedestrians by using laser range scanners. in *IROS IEEE/RSJ International Conference on Intelligent Robots and Systems* (2007) 2174–2179
16. Shi, Y., Ji, S., Shao, X., Yang, P., Wu, W., Shi, Z., Shibasaki, R.: Fusion of a panoramic camera and 2D laser scanner data for constrained bundle adjustment in GPS-denied environments. *Image and Vision Computing*, vol. 40, (2015) 28–37
17. Alvarez-Santos, V., Canedo-Rodríguez, A., Iglesias, R., Pardo, X., Regueiro, C., Fernandez-Delgado, M.: Route learning and reproduction in a tour-guide robot. *Robotics and Autonomous Systems*, vol. 63, Part 2 (2015) 206–213
18. Li X., Guskov, I.: Multi-scale features for approximate alignment of point-based surfaces. in *Proceedings of the Third Eurographics Symposium on Geometry Processing* (2005)
19. Guo, Y., Bennamoun, M., Sohel, F., Lu, M., Wan, J.: 3D object recognition in cluttered scenes with local surface features: A survey. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 36, no. 11 (2014) 2270–2287
20. Madry, M., Ek, C., Detry, R., Hang, K., Kragic, D.: Improving generalization for 3D object categorization with global structure histograms. in *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS)* (2012) 1379–1386
21. Rusu, R. B., Bradski, G., Thibaux, R., Hsu, J.: 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)* (2010)
22. Choe, Y., Ahn, S., Chung, M. J.: Online urban object recognition in point clouds using consecutive point information for urban robotic missions. *Robotics and Autonomous Systems*, vol. 62, no. 8, (2014) 1130–1152
23. Aijazi, A. K., Serna, A., Marcotegui, B., Checchin, P., Trassoudaine, L.: Segmentation and Classification of 3D Urban Point Clouds: Comparison and Combination of Two Approaches. Cham: Springer International Publishing (2016) 201–216
24. Lee, M., Hur, S., Park, Y.: An obstacle classification method using multi-feature comparison based on 2D LIDAR database. in *12th International Conference on Information Technology - New Generations (ITNG)* (2015) 674–679

25. Sipiran, I. Bustos, B.: Harris 3D: A robust extension of the Harris operator for interest point detection on 3D meshes. *Vis. Comput.*, vol. 27, no. 11, (2011) 963–976
26. Csurka, G., Dance, C. R., Fan, L., Willamowski, J., Bray, C.: Visual categorization with bags of keypoints. in *In Workshop on Statistical Learning in Computer Vision (2004)* 1–22
27. Flint, A., Dick, A., Hengel, A. V. D.: Thrift: Local 3D structure recognition in 9th Biennial Conference of the Australian Pattern Recognition Society on Digital Image Computing Techniques and Applications (2007) 182–188
28. Zaharia, T., Preteux, F.: Three-dimensional shape-based retrieval within the MPEG-7 framework in *Proceedings SPIE Conference on Nonlinear Image Processing and Pattern Analysis XII*, vol. 4304 (2001) 133–145
29. Lloyd, S.: Least squares quantization in PCM. *IEEE Trans. Inf. Theor.*, vol. 28, no. 2 (2006) 129–137