

Válasz

Dr. Hajdu András professzor úr

a „Térinformatikai módszerek és technológiák a felszíni közúti közlekedésben”
című MTA doktori értekezésemre írt opponensi véleményére

Legelőször szeretném megköszönni Professzor úrnak, hogy rendkívül alaposan és lényegre törő kérdésekkel elkészítette bírálatát. Válaszomban reagálni szeretnék az általános felvetésekre, és a konkrét kérdésekre is választ adok. Az érthetőség érdekében a Bíráló kérdéseit kék színnel emeltem ki.

Általános észrevételek

Bírálóm az 1. fejezettel kapcsolatban megállapítja, hogy „a tartalom kissé általános, sokkal inkább a térinformatika általános küldetését magyarázza el”. Ennek az általános bevezető jellegnek a magyarázata az, hogy a Magyar Tudományos Akadémia tudományos osztályai közül a X. Földtudományi Osztályon belül működik egy Geodéziai és Geoinformatikai Tudományos Bizottság (GGTB), azon belül pedig egy Geoinformatikai Albizottság. Ugyanakkor a Természetföldrajzi Tudományos Bizottságon belül is létrehozta a Geoinformatikai Albizottságot. A két térinformatikai albizottság az MTA besorolása szerint a földtudományok részeként tekinthető. A Budapesti Műszaki és Gazdaságtudományi Egyetem Építőmérnöki Karán végzett kutató munkám azonban sokkal szorosabb kapcsolatot tükröz véleményem szerint a Műszaki Tudományok Osztályához tartozó Közlekedés- és Járműtudományi Bizottsághoz. Éppen a szakmai közelség miatt jelentkeztem át a Műszaki Osztályhoz a PhD megszerzését követő földtudományi (GGTB) belépés után. A disszertációm első fejezetében szerettem volna megmutatni, hogy a térinformatikai háttér a közlekedéstudomány számára természetes integrációt jelent, ami nem mond ellent az általános küldetésének, hanem éppen annak célzott, sokszor igényvezérelt alkalmazása.

Észrevételek a 2. fejezettel kapcsolatban

Az 1990-es évekből származó szakirodalmi hivatkozások szerepeltetésének oka az, hogy a kutatásaim bemutatásánál szereplő cikkek az akkori szakirodalomra támaszkodtak. Egyetértek Professzor úrral abban, hogy jó lett volna foglalkozni a jelen szakirodalmával, bemutatva azt, hogy ma hol tart az adott terület. Mára azonban a különféle diszruptív technológiáknak köszönhetően több helyen radikális változások zajlottak le, például a terepi felmérő rendszerünk fejlesztésekor elérhető kameratechnológia műszaki paraméterei (pl. geometriai felbontás, adatátviteli sávszélesség) vagy a lézerszkennerek árai és hozzáférhetősége.

A 2.1. ábrán is látható téglalap modellen túl lehetne-e picit rugalmasabb reprezentáció, ami görbületet is képes visszaadni (körcikk, stb.)?

A bemutatott modell a legegyszerűbb geometriai primitív területi kiterjedésű térinformatikai objektumként. Ennek az alapelemnek a leírásához a két rövid oldalelező pont x és y koordinátáinak megadása, valamint a w félszélesség szükséges. A kiértékelési folyamatban alkalmazott genetikus algoritmus (azon belül a differenciális evolúciós technika) ezt az 5 dimenziót tekinti szabadon változtatható paraméternek, azaz a populáció egyedeit alkotó gének szabad változói lesznek a felsorolt elemek. A megadott paraméterekkel definiált téglalap képi maszkként kivág az előfeldolgozott képből, majd ennek a kivágnak megfelelően állapítja meg a gén fitness-értékét, amely a későbbi evolúciós lépésekben vezérli a gének kezelését (kihalás, rendeződés a legjobbtól a legrosszabbig stb.)

A fentiek persze nem zárnak ki más rugalmasabb reprezentációt, azaz alkalmas geometriai primitívként a körcikk szintén értelmezhető. Esetében az egyértelmű leíráshoz szükséges paraméterek a következők lehetnek: a körcikk K középpontjának x és y koordinátái, a körcikk r sugara, továbbá a kezdő- és ω

záróirányszög. Ez összesen szintén 5 paraméter, ami összevethető számítási komplexitást jelent a genetikus eljárás számára. Megjegyzem, hogy a kicsiny téglalapokból létrehozható nagyobb számosságú, alkalmas fitness-értékkel rendelkező populáció a végeselemes módszerekhez hasonlóan megfelel tetszőleges bonyolultságú útfelületek, -hálózatok leírására. A homogén elemekből álló populáció létrehozása viszont ellentmond az így bevezethető további elemeknek.

A dolgozat nem magyarázza el pontosan, hogyan történik a pontosság mérése, így például a 2.2. táblázatban szereplő accuracy értékek definíciója nem részletezett. Hogyan vannak ezek pontosan definiálva?

A dolgozat 2.2. táblázatában egy bináris tévesztési mátrix látható, amely kibővítésre került a távérzékelésben használt pontosság (*accuracy*) és hiba (*error*) mennyiségekkel. Az összes vizsgált pixel száma 1769 volt, 1146 a *true positive* (TP), 481 a *true negative* (TN) és 142 *false negative* (FN). A *false positive* (FP) pixelek számossága zérus. A mátrix soraiban a referencia, az oszlopokban pedig a kapott osztályozás értékei szerepelnek.

A megjelölt pontossági és hibaértékek definíciója egy korábbi cikkünk alapján (Á. Barsi *et al.*, 2018):

$$PA = \frac{TP}{TP + FN}; UA = \frac{TP}{TP + FP}; OA = \frac{TP + TN}{TP + FP + FN + TN}; OE = 1 - PA; CE = 1 - UA$$

Miért 200 a kezdeti populáció egyedszáma? Ez az érték hogyan került meghatározásra?

A kezdeti populáció nagyságát tapasztalati úton határoztam meg; ez volt az a méret, amit a rendelkezésre álló számítógép még elfogadható számítási idővel tudott kezelni. Ma már jelentősen nagyobb populációmérettel végezném a számításokat.

A 2.2.1 szakasz utolsó bekezdésében említésre kerül a mesterséges neurális hálózatok használata, de nem világos, hogy ebben a szakaszban hol jelennek meg a neurális hálók?

A megfogalmazásom alapja, hogy a dolgozatban említett *Support Vector Machine* (SVM) módszer a tézist alátámasztó cikk írásakor a neurális hálózatok csoportjába került besorolásra. 1995-ben az első cikk írói, C. Cortes és V. Vapnik maguk is így értelmezték, s Rosenblatt perceptron-modelljére, majd a későbbi neurális hálózat kutatóinak, D. Rummelhart, G. Hinton és mások munkáira hivatkoznak (Cortes & Vapnik, 1995). Ma inkább az ún. sekély (*shallow*) neurális hálózatok közé lehetne sorolni, de talán pontosabb csak a gépi tanulás (*machine learning*) módszereként említeni.

A 2. fejezet minden szakaszával (2.2.1, 2.2.2, 2.3.1, 2.3.2) kapcsolatban felmerül az alábbi két kérdés:

1. mi volt pontosan a metodológiai újszerűség, melyek azok az elemek, amik még nem jelentek meg az (akkori) szakirodalomban ezekhez a feladatokhoz?

A 2.2.1 alfejezetben leírt eredmény a differenciális evolúciós technika alkalmazása, amihez előfeldolgozással nyert bináris képet használtam. A 2.2.2. alfejezetben a Radon-transzformáció és a növekvő neurális gáz, a 2.3.1 alfejezetben a Hough-transzformáció implementálása nevezhető meg úrfelvétel, illetve légifénykép feldolgozási folyamatában. Ugyanitt a fő fejlesztés a JEANS-módszer volt, amely különböző feature-ök kinyerése után *backpropagation* neurális hálózat segítségével végzett csomópont-felismerést. A 2.3.2 alfejezetben a T. Kohonen által kidolgozott önszerveződő neurális hálózatnak, a SOM-nak (*Self-Organizing Map*) adtam meg egy lehetséges általánosítását. Ez az önszerveződő neurongráf modell, a SONG (*Self-Organizing Neuron Graph*) a Kohonen-féle versengő tanulás módszerét egy előre definiált gráfba szervezett neuronrétegre alkalmazza. A SONG kompetitív tanulása során a gráffal leírt, tetszőleges topológiájú neuronok között értelmezem a szomszédságot, s adom meg a súlyok módosításának összefüggéseit. Ez utóbbi eljárást tartom a fejezet legjelentősebb eredményének, mivel teljesen saját kutatási eredmény; ezt egy Springer Lecture Notes kiadványban közöltem (Barsi, 2003).

2. miért nincsenek összehasonlítva kvantitatív módon mind a saját módszerek egymással (különös tekintettel erre a megjegyzésre: „...ugyanerre az eredményre vezető”, dolgozat 22. oldal), mind más irodalmi útdetektálási módszerekkel? Hogyan látható a pontosság javulása?

A fejezet elején bemutatott Hough-transzformációs megoldásokkal egyidejűleg dolgoztam a neurális hálózatokat alkalmazó JEANS-eljáráson, s a két szakasz szövegét kötöttem össze az „ugyanerre az eredményre vezető” kifejezéssel. A megközelítés azt tartalmazza, hogy mindkét módszertant a kereszteződések detekciójára kívántam alkalmazni.

A 2.3.2 szakaszban egyszerű küszöbölés kerül említésre előfeldolgozásként. Más eljárások nem kerültek megvizsgálásra? Remélhetünk jobb eredményt kifinomultabb előfeldolgozással?

Az újonnan kidolgozott SONG-megoldás előtt egyszerű küszöbölést használtam előfeldolgozásként. A SONG eleinte tisztán szintetikus teszteken futott, szerettem volna igazi távérzékelési adatokon is vizsgálni. Úgy véltem, hogy az előfeldolgozással kapott megközelítő szegmentálás elegendő minőségű nyersanyagot jelent a SONG számára. Egyetértek ugyanakkor a tisztelt Bírálóval, hogy kifinomultabb előfeldolgozás jobb eredményt képes szolgáltatni. Hasonlóképp komplexebben megadott gráfstruktúra is nagyobb várható illeszkedést képes elérni.

Észrevételek a 3. fejezettel kapcsolatban

Az útpálya felmérésével kapcsolatos források alapján az irodalmi áttekintést lényegre törően kívántam elkészíteni. A hivatkozott cikkek, pl. (Bossler & Toth, 1996) bemutatják a felmérési igényeket és az egyik elsőként kifejlesztett felmérő rendszer koncepcióját.

A 3.2.1 fejezetben ismertetett sztereokamerás változat fejlesztése meglehetősen hosszú ideig tartott: 2004-ben készült el a koncepcióterv, a rendszer végleges dokumentálását 2008-ban adtuk át a megrendelő Fővárosi Közterület-fenntartó Rt. (FKF) részére, de 2011-ig még folyamatos karbantartást biztosítottunk és az új tudományos eredményekről publikációban számoltunk be (Kertész, Lovas & Barsi, 2008; Lovas *et al.*, 2008; Kertész & Barsi, 2010). Sajnos a monokamerás változat csak a koncepciótervig jutott el, néhány deszkamodell-kísérlet végrehajtása történhetett meg.

A 3.4 szakaszban leírt híd-méréstechnika fejezettel a célom az volt, hogy az infrastruktúra lézerszkenneléses felméréséről teljesebb képet adhassak. Ebben a fejezetben azért nem fogalmazok meg altézist, mivel csapatban dolgoztunk – intenzív részvételemmel a matematikai modellezésben –, ugyanakkor tanszéki kollégám, Dr. Lovas Tamás szűkebb kutatási területéhez tartozik, aki MTA doktori értekezést kíván a közeljövőben benyújtani.

A következő részeknél nem találtam irodalmi áttekintést, ami segítette volna annak eldöntését, hogy a megközelítést/módszertant használták-e már mások?

A kérdés a sztereofotogrammetriai elven működő burkolatfelmérő műszeregyüttesre vonatkozik. A PHORMS sztereokamerás rendszerét 3 éven keresztül az FKF (később a jogutód Budapest Közút) terepi adatgyűjtésre használta és felmért 800 km fővárosi főutat. Az erről készített felmérési térképet mutatja az értekezés 3.13. ábrája.

A számítógépes tomográfiás vizsgálati módszerünkről írt Fourier-transzformációs cikkünk (Kapitány & Barsi, 2016) Q1-es folyóiratban jelent meg, a kiadó ASCE Library szerint máig 200 letöltéssel rendelkezik.


1. 3.2.1 szakasz, különös tekintettel az előmetszéses pontmeghatározási technikára (mik itt a saját, új módszertani elemek?), a két műszer adatainak egyesítésére használt Kálmán szűrésre (itt mi az új elem?), a Neutra eljárásra (itt mi az új az említésre kerülő automatikus pontdetektálási eljárásra (itt van-e/mi az újdonság?)

A 3.2.1 szakaszban tárgyalt sztereokamerás rendszer a fotogrammetriai előmetszés alapelvét alkalmazza. Ismereteim szerint egyetlen mobil térképező rendszer sem használ(t) ilyen megoldást az útinfrastuktúra felmérésére. A svéd RST rendszere nagyban hasonlít a PHORMS-hoz, mivel a burkolatról 11 pontban nyer felületmagassági információt. A 21 lézer pontvetítővel megvalósított felületi pontjelölési eljárásunk új; ezzel sikerült biztosítani a homogén burkolati felszínen jól azonosítható diszkrét pontok felismerését és pontos

geometriai meghatározását. A lézervetítőknél köszönhetően a rendszer a környezeti megvilágítástól függetlenné vált. A rendszerben üzemelő kamerák fényérzékenysége miatt inkább áttértünk a sötétedés utáni mérésre, ráadásul így a forgalom sem okozott akadályt a felmérésben.

A hely- és helyzetmeghatározásban alkalmazott Kálmán-szűrés teljesen elfogadott módszer, implementálása gyakorlatilag az irodalom alapján történt.

A Neutra koordináta-transzformáció kifejezetten Magyarország területére kidolgozott koordináta-transzformációs módszer, amelyhez az ország teljes területén elhelyezkedő WGS84 és EOVS rendszerekben adott közös pontok szolgáltak alapul. A módszer központjában egy neurális hálózat áll, amely megvalósítja a leképezést a két vonatkozási rendszer között. A német nyelvű *Allgemeine Vermessungs-Nachrichten* lapban publikáltam a módszertan lényegét (Barsi, 2001), a hazai szakembereknek szánt részletesebb vizsgálat a magyar Geodézia és Kartográfia lapban jelent meg (Barsi, 1999). Az értekezésben megadtam a pontosságra vonatkozó számítások statisztikai jellemzőit, a számítási hibák térbeli eloszlása Magyarország területére az alábbi ábrán látható.



1. ábra: Transzformációs hibák térbeli eloszlása Magyarországon

A Neutra-megoldás első cikkére az MTMT-ben 16 idéző szerepel, például (Awange & Grafarend, 2005).

2. 3.2.2 szakasz (létezik a monokamerás megközelítés és bemutatott módszertan másoknál?)

A monokamerás működési elvet (*optical triangulation*, *structured light scanning* vagy *profilometry* néven) a mai tárgyszkenner és ipari minőségellenőrző berendezések alkalmazzák, ezek általában limitált méretű tárgyak digitalizálására szolgálnak. A tárgyszkennerrel rögzített helyen, többnyire forgóasztalon elhelyezett, vagy futószalagon mozgatott tárgyakat lehet nagyfelbontással felületként digitalizálni. Ilyen berendezések például a Keyence Laser Profiler eszközei.

Útburkolat felületének mérésére tudomásom szerint nem alkalmaznak lézermarkerek és fotogrammetriai kameratechnológián alapuló mérési elvet. A mai mobil térképezők nemcsak az útfelület, hanem annak környezetének felmérésére hivatottak, aminek megvalósításához többnyire két elforgatott, döntött helyzetű lézerprofilszkenner használnak. A mai technológiának elengedhetetlen feltétele volt az az óriási fejlődés, amin a mobil lézershennerek az utóbbi években átestek.

3. 3.2.3 szakasz (mennyire új a megközelítés? mik az új elemek?)

A földi (TLS) és mobil (MLS) lézershennerek segítségével nagyfelbontásban lehetséges az útpálya felületéről pontfelhőt előállítani. Ebből a pontfelhőből a módszerem révén végelelemes modell jött létre, amelynek alkalmazására a sávváltásokban nyújtott segítséget mutatom be. A nagyfelbontású térképek (*high-definition* – HD-térképek) készítői között csak az eredetileg német, mára multinacionális céggé alakult

Elektrobit használ hasonlóan dedikált rácsmodellt, erről azonban rendkívül kevés műszaki információ érhető el.

Az OpenCRG modellje 2007-ban jelent meg, alapvetően a német VIRES cég szimulátorában használt burkolatléíró eljárás. Az értekezésben ismertetett folyamat lényege, hogy biztosítsa a lézerszkenneléssel nyert pontfelhő OpenCRG szabványnak megfelelő betöltését és felhasználását. A kidolgozott technológia célkitűzése a megfelelő geometriai transzformáció elvégzése és az adatok betöltése a szabványos adatstruktúrába.

4. 3.3. szakasz (használtak mások is tomográfias megközelítést a célra? a Fouriertranszformáción alapuló képjavító eljárás mennyiben új? a nyalábkeményedés effektusának korrekciójában vannak új elemek?)


A Fourier-transzformáció használata a CT-vel nyert anyagminták szemcseszerkezetének elemzésében új megoldás. A nyalábkeményedés (*beam hardening*) korrekciójára a legismertebb módszerek a következők: hardveres szűrés, linearizálás, duál-energia módszer. Eljárásunk a számításos modelljavítások közé tartozik; nem ismerünk ezen transzformáción alapuló más hasonló módszert.

Az előző kérdéshez kötődően, ahol a megközelítés másoknál is létezik, milyen kvantitatív összehasonlítás végezhető el a saját eredményekkel kapcsolatban? Kimutatható javulás?

A nyalábkeményedés hatásának csökkentésére az irodalomban számos publikációt találunk, ezek közül alapos rendszerezése okán (Van de Casteele *et al.*, 2004) cikkét emelem ki. A transzformációs eljárásban való részvételem ellenére ebben a megoldásban nem foglalmaztam altézist, mert az Építőmérnöki Karon dolgozó kollégáim (Dr. Lublőy Éva és Dr. Kapitány Kristóf) ezekből az eredményekből saját MTA doktori értekezést terveznek benyújtani.

A 3.2.1 szakaszban említésre kerül a „az elvárható legjobb geometriai pontosság” elérése a burkolatméréssel kapcsolatban. Ez a pontossági érték hogyan van pontosan definiálva?

Az elvárható legnagyobb pontosság gyakorlati jelentőségű, mivel a kamerakalibrációval megállapított torzítás az elrajzolásmodellel képkorrekcióra válik alkalmassá, amivel a kamerák által nyert képeken nagy pontossággal lehet a pixelek helyét meghatározni, majd pedig az előmetszéssel a tárgypontok koordinátáit számítani. Összességében ezzel a javított kameramoddellel a tárgypont-koordináták lesznek jobb minőségűek. A kalibráció során koordinátamérő műszerrel hitelesített kalibrációs mező rúdjaival is ellenőriztük a kamerák képalkotását (2. ábra) (Tóth, Mélykúti & Barsi, 2005).



2. ábra: Kalibrációs mező és a hitelesítő műszere

A 3.2.3 szakaszban szerepel a „Matlab és a sokkal hatékonyabb C++nyelven írt” megjegyzés. Itt pontosan mire vonatkozik a nagyobb hatékonyság (pl. Matlab alá is befordítható C/C++ kód)?

Köszönöm a pontatlan megfogalmazásom kiemelését. Valóban lehetséges C/C++ eljárások befordítása Matlab alá, s ezekkel az ún. MEX-függvényekkel a nagy számítási sebességet a kompilált megoldás jelenti a

Matlab (ugyan optimalizált, de alapvetően interpreteres) függvényeivel szemben. A szakaszban az állítás arra vonatkozik, hogy a például földi lézerszkenneléssel (TLS) előállított milliós vagy milliárdos számosságú pontfelhő pontjainak betöltése az OpenCRG rácsába kevesebb futásidővel érhető el, amennyiben C++ nyelvű rutinnal történik meg. A Matlab környezetben kidolgozott megoldás prototípus kifejlesztésének tekinthető.

A 3.3 szakaszban nem találtam arra vonatkozó információt, hogy hány fizikai minta állt rendelkezésre a burkolatokból. Az alacsony mintaelemszám statisztikai szempontból aggályossá teheti a levont következtetéseket. A bemutatott eredmények statisztikailag relevánsnak tekinthetők?

A szakaszban leírt módszerhez használt anyagminta előállítása humán CT-berendezések „melléküzemeltetésével” történt, mivel akkoriban nem volt számunkra ipari CT elérhető. A vizsgálatokban ezért tízes nagyságrendben tudtunk beton- és aszfaltminták CT-felvételezését végezni. Bízom benne, hogy hamarosan hatékony nagytömegű minta CT-zésére nyílik mód. A validálás körülményes invazív laboratóriumi vizsgálattal valósítható meg; ezt minden leírt minta esetében kollégáim elvégezték.

Észrevételek a 4. fejezettel kapcsolatban

A 4.1 szakaszban SVM típusú hálózatok (mint neurális hálózatok) említése történik, miközben az SVM klasszikusan egy egyszerű (neurális hálók nélkül is alkalmazott) osztályozási technika. Mi az oka ennek a megfogalmazásnak?


A 2.2.1 szakaszban már felmerült ugyanez a kérdés; (Cortes & Vapnik, 1995) cikkét alapnak tekintve soroltam az SVM módszert én is a neurális hálózatok közé.

A 4.3 ábra angol nyelvű. Ez saját ábra vagy átvételre került valahonnan?

Az ábra saját szerkesztésű, a következő publikációban jelent meg: (Somogyi & Barsi, 2016).


A 4.2 szakaszban az SOM technikán alapuló szegmentáció kerül bemutatásra, mint választott technika. Történt-e összehasonlítás más szegmentációs módszerekkel, hátha azok jobb eredményt adtak volna? Hogyan, milyen kiértékelési protokoll segítségével lett tesztelve az SOM szegmentáció hatékonysága? Mekkora adatbázison lett tesztelve?

Az első cél a SOM-szegmentációs munka során egy Landsat 7 felvétel feldolgozása volt. Ez a kép 30×30 m-es pixelmérettel rendelkezik 7 multispektrális sávban, amihez még egy 15×15 m-es pankromatikus sáv is járul. A távérzékelte felvétel osztályozása Erdas Imagine 9.1 szoftverrel történt. Ennek a felvételnek a feldolgozását ISODATA klaszterezéssel végeztük el, 6 klaszter megadásával maximum 10 iterációval és 95%-os konvergencia-küszöbértékkel. Összehasonlítás céljából továbbá 7-osztályos maximum likelihood osztályozást is végrehajtottunk (3. ábra).




3. ábra: Tesztállomány és hagyományos feldolgozási eredmények

A SOM-feldolgozás 16 klaszterre bontotta a felvételt, amit utófeldolgozással a valóságnak közel megfeleltethető 6 tematikus osztályba rendeztünk. Ennek eredménye a 4. ábra.



4. ábra: SOM-klasszifikáció az eredeti kép hátteret nem tartalmazó 3000 × 3000 pixeles kivágatára

A képrészletek vizuális ellenőrzése után tapasztalt, részleteiben jó feldolgozási eredmények után nagyobb geometriai felbontású űrfelvételen is alkalmaztuk a SOM-technikát, ezért a Margit-sziget környezetére egy 2.4-2.8 m pixelméretű Quickbird műhold három látható és egy közeli infravörös csatornából álló felvételére is futtattuk az eljárást. Első lépésben a Quickbird-képből újramintavételezéssel előállítottuk a Landsat 30×30 m-es felbontását, majd azon a képen teszteltünk. Az eredmény az 5. ábrán látható.



5. ábra: Újramintavételezett Quickbird-felvétel feldolgozása SOM-osztályozóval

Az említett vizsgálatok TDK-zó és diplomázó hallgatóm, Gáspár Katalin „Képelemzés önszerveződő neurális hálózattal” című dolgozataiban szerepelnek részleteiben.

A 4.2 szakasz végén egy alkalmazás a szerző 2018-as cikkét jelöli meg (Barsi et al., 2018). Az eljárás szegmentációt is használ, viszont 2018-ban már bőven elérhetőek voltak a mélytanuláson alapuló szegmentációs eljárások. Miért nem kerültek be ezek az eljárások a megvalósításba (relatív magasságon alapuló szegmentálás)?

Az (Árpád Barsi et al., 2018) cikk a BME kampuszának földi lézerszkenneres (TLS) felmérésének feldolgozásáról szól. A cikkben több álláspontból kapott mérés együttes pontfelhőjét georeferáltuk, majd a járható utak magasságának környezetében magassági vágással eltávolítottuk a fölösleges pontokat és az így kapott redukált méretű állományon fokozatos manuális magassági finomítással közelítettünk az útpályához. Mivel a burkolat anyaga maga is többféle volt: aszfalt, kiskockakő, kavics; továbbá több közmű változatos méretű és anyagú (szintben sajnos eltérő) fedlapja is megtalálható volt, kiemelt szegéllyel és anélkül, valamint

a borításhatároknál voltak azonos szintben található felületek, ezért a leghatékonyabb megoldás a manuális (ellenőrzéssel) elvégzett magassági szegmentálás volt. Ezt a pontfelhő intenzitásértékeinek mint színeknek a figyelembe vételével nagyban lehetett segíteni. Ezt követően a burkolat felületelemeinek különálló határolóvonalalaiból zárt felületeket képeztünk vektoros GIS rendszerben (QGIS-ben), majd ugyanabban a szoftverben raszteres formátumra konvertáltuk, hogy a további járműtrajektória tervezéshez megfelelő alapot biztosítson. *Deep learning* eljárás felhasználásával elképzelhető a feladat elvégzése, azonban a gyors eredményhez és a viszonylag kis kiterjedésű területhez problémát jelentene ennek alkalmazása. További nehézségnek tartom a megfelelő számú annotált adat hiányát; ezek létrehozása már a munka tényleges elvégzése. Ennek ellenére köszönöm az ötletet, mindenképpen le fogom tesztelni a közeljövőben.

Észrevételek az 5. fejezettel kapcsolatban

A fejezet általános értékelésében egy konkrét felvetésre szeretnék reflektálni. A forgalommal szembehajtó jármű felismerése olyan feladat volt, amiben kezdetben teljesen szabad kezdet kaptunk a keretet adó EU FP7 keretprogramban. A hardver-választásunk az RFID-re esett, ki kellett fejleszteni nemcsak a feldolgozó eljárást, hanem az ahhoz szükséges eszközkonfigurációt is. Ezután szereztük be az antennákat, tag-eket és csatlakozókat. Elképzelésünk szerint egy kis (~6 m) hatótávolságú rendszerben prototípust hoztunk létre, majd ezt követően tértünk át a valós (a rendszerben 100 m-es hatótávolságot jelentő) kialakításra. A hardver beüzemelése mellett ide tartozott a master-slave elrendezés létrehozása is, ami a két antennát kezelő számítógép nagysebességű kommunikációját is igényelte. Ehhez az UDP protokoll felhasználásával adattovábbító mechanizmust kellett programozni. A fenti lépések legnagyobb részét én végeztem, nyilvánvalóan a teszteléshez egy kis csapat támogatását kaptam meg kollégáimtól és doktoranduszaimtól.

Az 5.2 szakaszban nem igazán világos, hogy milyen új elemek vannak a javasolt metodológiában, vagy az implementáció volt az elsődleges célkitűzés? Történt kvantitatív összehasonlítás más módszerekkel?

Az 5.2. fejezetben több eljárás alkalmazhatóságát is bemutatom. A kameraképek feldolgozásában az EU INTAS projektjében német partnerünk által fejlesztett rendszer minőségvizsgálatát végeztük. A Quickbird felvétel közel 2.5 m-es felbontásának tesztelése arra vonatkozott, hogy alkalmas-e járműfelismerés elvégzésére. Az akciókamera közlekedési alkalmazása arra irányult, hogy egyszerű és olcsó eszköz segítségével megvalósítható-e forgalomfigyelés és járművezetői viselkedés számszerűsítése (pl. jelzőlámpánál vagy kocsisorban követési idők megállapítása), azaz itt az implementálhatóság volt az elsődleges. A légi lézerszkennelés (ALS) adatsoraival megvizsgáltuk, hogy a földi lézerszkenneléshez (TLS) hasonlóan van-e mód pontos járműmodellek elkészítésére, mivel a korábbi projekt célja az ALS-alapú forgalomfigyelés és -számlálás volt. A fejezet végén a profilszkennerterepi tesztjének, s ezzel a forgalomfigyelés implementációjának vizsgálatát mutatom be.

A legtöbb módszernél, ahol nem kifejezetten az implementáció prioritása volt a fő ok, a validálás manuális forgalomszámlálással történt meg. Például az utóbbi profilszkennert alkalmazásban Intelligens közlekedési rendszerek című MSc-s tárgyunkban hallgatói közreműködéssel értékeltük ki az automatikusan nyert eredményeket. Az ALS-alapú forgalomszámlálás szintén manuális járműszámlálással került ellenőrzésre.

Az 5.1. táblázat a leírás alapján a járműosztályozás pontosságát tartalmazza, viszont a százalékos értékek nagyon alacsonyak benne. Valószínű az értékek, vagy máshogy kell értelmezni?

Köszönöm szépen a kérdést, valóban a táblázat adataira hibásan hivatkoztam. Az egyes értékek és százalékok a hibásan besorolt járművek számát (*misclassification error*) jelentik. Mindhárom módszer a gépi tanuláshoz tartozik, érdekes volt ezek egymáshoz viszonyított teljesítményét megvizsgálni. 2003-hoz képest ma már bővebb eljárás-választékból lehet ezt a tesztet elvégezni.

Az 5.4. szakaszban a gyalogosok detektálására a GMM modell kerül alkalmazásra. Gyalogosdetektálásra nagyon sok eljárás volt mindig is ismert, így természetesnek tűnik a kérdés, hogy miért ez a módszer került kiválasztásra? Történt összehasonlítás más potenciális eljárásokkal?

A gyalogosdetektálás feladatának „megihletője” az az MSc-s tárgy (Intelligens közlekedési rendszerek) volt, amelyben egy hallgatói csoportnak szerettem volna kamera és Kálmán-szűrés felhasználását bemutatni. Ehhez a Matlab-ban rendelkezésemre állt kész GMM-eljárás, amihez kidolgoztam az akciókamera segítségével rögzített felvételek torzításmentesítését, georeferálását, továbbá a GMM segítségével detektált gyalogosok Kálmán-szűréssel végzett trajektória-simítását. Az így felépülő komplex technológia tematikus pontossága megfelelő, ezt a terepi validáció megerősítette. Ezen túlmenően a megoldás az oktatásban (forgalomsűrűség meghatározása, térhasználat szemléltetése és a gyalogos közlekedés minősítésének céljaira) is hasznos.

Az 5.4. szakaszban helyet kap a Kinect szenzor is, ami gyakran használt emberek detektálására, viszont a leírás nem tartalmaz irodalmi kitekintést. Történ bármilyen összehasonlítás más Kinect-alapú megközelítésekkel a feladatra?

A Kinect, mint Flash-Lidar kalibrációja és fotogrammetriai alkalmazhatósága volt doktoranduszom, jelenlegi kollégám, Dr. Molnár Bence kutatása volt. A vele végzett pontossági elemzések sok irodalmi áttekintést hasznosítottak. A dolgozatomban Kinect-re alapozott gyalogosfolyam rögzítésének és automatikus feldolgozásának módszertani bemutatása volt a cél. A folyosói Kinect-mérések a korábbi Sick LMS profilszkennelrel végzett mérések és automatikus feldolgozás eredményeivel kerültek összehasonlításra. A profilszkennel később kültéri gyalogos-kerékpáros konfliktuszóna vizsgálatára is szolgált (Erzsébet-híd projekt).

Még egyszer szeretném megköszönni Professzor úrnak az alapos bírálatot, igyekeztem minden kérdésére körültekintően válaszolni. Elnézést kérek a kissé terjedelmes válaszáért.

Budapest, 2021. február 14.

Barsi Árpád

Irodalom

- Awange, Joseph L. & Grafarend, Erik W. (2005) *Solving algebraic computational problems in geodesy and geoinformatics: The answer to modern challenges*, *Solving Algebraic Computational Problems in Geodesy and Geoinformatics: The Answer to Modern Challenges*. Springer Berlin Heidelberg. doi: 10.1007/b138214.
- Barsi, A. (2003) 'Neural Self-Organization Using Graphs', *LECTURE NOTES IN COMPUTER SCIENCE*, Vol. 2734, pp. 343–352
- Barsi, Á., Kugler, Zs., László, I., Szabó, Gy. & Abdulmutalib, H. M. (2018) 'Accuracy dimensions in remote sensing', in *International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences - ISPRS Archives*. doi: 10.5194/isprs-archives-XLII-3-61-2018.
- Barsi, Árpád (1999) 'Koordináta-transzformáció megoldása neurális hálózattal', *GEODÉZIA ÉS KARTOGRAFIA*, Vol. LI, No. 10, pp. 12–18
- Barsi, Árpád (2001) 'Performing coordinate transformation by artificial neural network', *ALLGEMEINE VERMESSUNGS-NACHRICHTEN*, Vol. 108, No. 4, pp. 134–137

- Barsi, Árpád, Nyerges, Ádám, Potó, Vivien & Tihanyi, Viktor (2018) 'AN OFFLINE PATH PLANNING METHOD FOR AUTONOMOUS VEHICLES', *Production Engineering Archives*, Vol. 19, pp. 37–42. doi: 10.30657/pea.2018.19.08.
- Bossler, J. D. & Toth, C. (1996) 'Feature positioning accuracy in mobile mapping: results obtained by the GPSvan', *International Archives of Photogrammetry and Remote. Sensing*, Vol. 31, No. Part 4, pp. 139–142
- Van de Casteele, E., Van Dyck, D., Sijbers, J. & Raman, E. (2004) 'A model-based correction method for beam hardening artefacts in X-ray microtomography', *Journal of X-Ray Science and Technology*. IOS Press, Vol. 12, No. 1, pp. 43–57
- Cortes, Corinna & Vapnik, Vladimir (1995) 'Support-vector networks', *Machine Learning*. Springer Science and Business Media LLC, Vol. 20, No. 3, pp. 273–297. doi: 10.1007/bf00994018.
- Kapitany, Kristof & Barsi, Arpad (2016) 'Fourier transformation-based CT correction method for geomaterial core samples', *Journal of Materials in Civil Engineering*, Vol. 28, No. 1. doi: 10.1061/(ASCE)MT.1943-5533.0001349.
- Kertész, Imre & Barsi, Árpád (2010) 'Tárgyrekonstrukció egy kamera és lézer segítségével', *GEOMATIKAI KÖZLEMÉNYEK*, Vol. XIII/1, pp. 51–57
- Kertész, Imre, Lovas, Tamás & Barsi, Árpád (2008) 'Photogrammetric pavement detection system', *INTERNATIONAL ARCHIVES OF PHOTOGRAMMETRY AND REMOTE SENSING (2002-)*, Vol. XXXVII, No. B5, pp. 897–902. Available at: <http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.184.2604&rep=rep1&type=pdf>.
- Lovas, T., Kertész, I., Fi, I. & Barsi, A. (2008) 'Photogrammetric pavement detection system', in *Pavement Cracking: Mechanisms, Modeling, Detection, Testing and Case Histories*
- Somogyi, Árpád & Barsi, Árpád (2016) 'Pixel-based 3D Object Reconstruction', in *11th International Symposium on Applied Informatics and Related Areas (AIS 2016)*. Budapest: Óbudai Egyetem, pp. 60–63
- Tóth, Zoltán, Mélykúti, Gábor & Barsi, Árpád (2005) 'Digitális videokamera kalibrációja', *GEOMATIKAI KÖZLEMÉNYEK*, Vol. 8, p. 297