

RAPORTARE ȘTIINȚIFIC ȘI TEHNIC 2022

Contract nr. 23PTE/2020

Etapă nr. 3/2021

Cod proiect: PN-III-P2-2.1-PTE-2019-0367;

*Titlu proiect: Servicii de transfer de cunoștințe pentru sisteme de percepție 3D
bazate pe AI*

Beneficiar: Analog Devices GMBH, România

Partener: Universitatea Tehnică din Cluj-Napoca

Rezumatul etapei 3 (Diseminare rezultate, raportare): Validarea algoritmilor de procesare ale camerei 3D de la ADI prin intermediul soluțiilor bazate pe IA; publicarea rezultatelor, protejarea PI. Rezultatele preconizate: publicații științifice, studii de caz, brevete.

Avizat:

Director de proiect:
Dr. Andrei Cozma

Etapa 3, fiind ultima etapă din proiect, a avut activitatea principală diseminarea rezultatelor. În sumar, s-au publicat 8 lucrari la conferinte internationale cotate ISI, 2 jurnale ISI de tip Q1, un brevet național (OSIM) și s-au dezvoltat 3 prototipuri de aplicații (demo-uri) pentru produsul SmartCam al partenerului economic Analog Devices, România.

În ceea ce urmează se vor prezenta aceste rezultate.

Activitate 3.1 Validarea algoritmilor dezvoltati

Această activitate avea drept scop validarea algoritmilor dezvoltati în etapele preliminare. Astfel, s-a concentrat pe aplicarea metodelor de prelucrare a informațiilor de la camere de tip Time of Flight (ToF) cu focus pe aplicații înglobate în domeniul de robotică și IA.

Perceperea activă în medii dinamice este o cerință specifică bazată pe tehnici de prelucrare a datelor de ToF precum: preprocesare, segmentare, îmbinare. Pentru îmbinarea eficientă a datelor 3D se folosesc repere (punte cheie) care oferă o robustețe sporită pentru aceste metode.

O variantă cu focus pe date de la camere 3D a fost dezvoltată și validată în această etapă, pentru care se poate vedea arhitectura propusă în Fig 1. Detaliile acestei metode sunt publicate în (9).

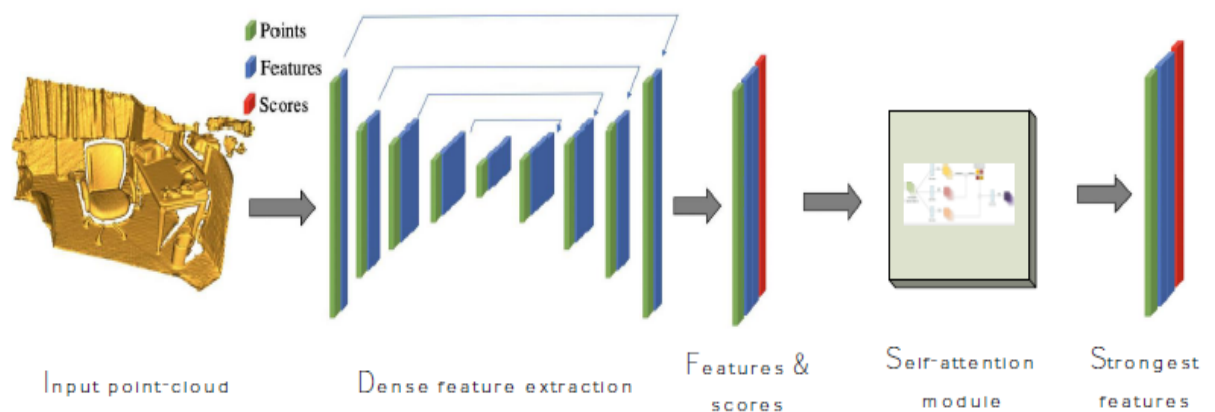


Fig. 1 Calcul optim de normale bazat pe transfer learning

Un aspect important pentru această metodă validată consideră implementarea și testarea acestuia folosind platforme înglobate. Acesta asigură aplicabilitatea metodei pe o scară mai largă folosind echipamente accesibile și cu consum redus.

Activitate 3.2 Diseminarea rezultatelor, raportare

Corectarea artifactelor în imagini de adâncime este o problemă relevantă atât în cercetare cât și în domeniul industrial (3). În acest domeniu o ramură specială reprezintă eliminarea artifactelor de tip MPI din nori de puncte 3D. Acesta din urmă are avantajul de a contribui la zone mai mari, compacte de date.

Focusul pentru această activitate din cadrul proiectului era pe eliminarea interferențelor de tip MPI .

Astfel s-a creat o aplicație care rulează pe o platformă înglobată în timp real, și elimină efectele nedorite de interferențe pentru planul major din imaginea de adâncime de la o cameră de tip ToF.




Fig. 2 Calcul optim de suprafețe planare

Metoda este bazată pe rețele profunde tip FPN care facilitează un timp de rulare redusă chiar și pe echipamente înglobate cu resurse constânse. Detaliile acestei metode sunt prezentate în lucrarea publicată (4).

Completarea datelor de la o cameră ToF este o problemă relevantă atât în cercetare (5) cât și în domeniul industrial (3). În acest domeniu o ramură specială reprezintă completarea de nori de puncte 3D. Acesta din urmă are avantajul de a contribui la o imagine de ansamblu în 3D.

Focusul pentru această activitate din cadrul proiectului era pe utilizarea algoritmilor de tip auto-encoder(AE), mai precis variational AE pentru acest scop (2).

Astfel s-a creat o aplicație care rulează pe o platformă înglobată în timp real, și poate completa o imagine de adâncime de la o cameră de tip ToF.

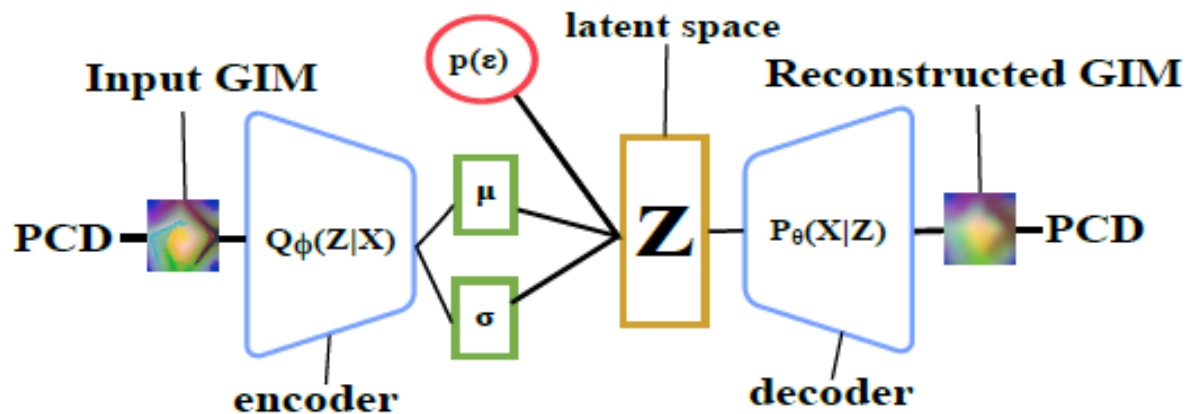


Fig. 3 Variantă de completare obiecte folosind VAE și reprezentare GIM

Arhitectura propusă bazată pe VAE este prezentată în Fig 3. Pentru reprezentarea eficientă a datelor 3D s-au folosit imaginile de tip geometry image, care au contribuit semnificativ la optimizarea timpului de rulare ale algoritmilor propuși pe platforme înglobate.

Detaliile și rezultatele metodei sunt diseminate în (6).

Pentru extragere inform iei de  ntr-un context de optimizare 6DoF s-a construit un lan  de procesare bazat pe re ele de tip PointNet sugerat   n Fig 4. Metoda  i rezultatele aferent au fost diseminate  n (7).




Fig. 4 Variant  de completare estimare a pozi iei folosind re ele de tip PointNet augmentate

Recunoa terea obiectelor este o problem  relevant  at t  n cercetare c t  i  n domeniul industrial.  n acest domeniu o ramur  special  reprezint  recunoa terea obiectelor din nori de puncte 3D. Acesta din urm  are avantajul de a avea informa ie topologic   i metric  pentru obiectele  n fa a camerei.

Focusul pentru aceast  activitate din cadrul proiectului era pe recunoa terea formelor 3D pentru a clasifica obiectele  n diferite clase geometrice (e.g. sfer , plan, cilindru, etc).

Astfel s-a creat o aplica ie care ruleaz  un lan  de procesare optimizat prezentat  n Fig 5.




Fig. 5 Varianta de procesare eficient  pentru date multi-modale
Validarea rezultatelor s-a publicat  n (1)  i (8).

O abordare diferită față de metodele convoluționale tradiționale reprezintă variantele cu operatorul în mediul spectral. Acestea asigură o reprezentare compactă, robustă a datelor. Această idee s-a validat în aplicația de clasificare folosind date 3D în domeniul spectral după cum este ilustrat în Fig 6.

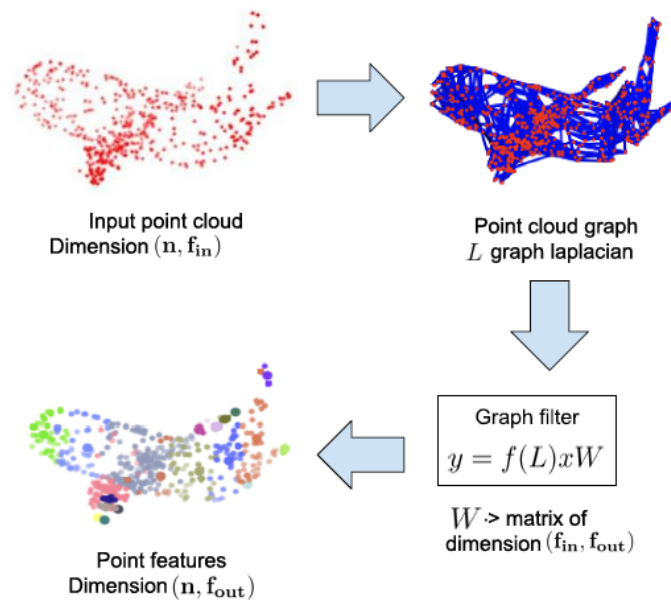


Fig. 6 Reprezentarea datelor într-un format compact folosind GNN spectral

Detaliile metodei propuse pentru procesarea datelor 3D folosind GNN spectral a fost diseminate în lucrarea (10).

Pentru fiecare metodă publicată codul sursă și documentația aferentă a fost publicată pe site-ul proiectului.

Concluzii

În concluzie, activitățile propuse în etapa 3 a proiectului au fost atinse cu succes (inclusiv pe partea de validarea algorimilor, diseminarea rezultatelor și faza de raportare), iar aceste rezultate au servit ca baza proiectelor depuse cu partenerul industrial la apeluri naționale (de tip PTE și PED) și internaționale (IPCEI).

Bibliografie

1. 3D object recognition using time of flight camera with embedded GPU on mobile robots, B Kelényi, S Molnár, L Tamas, VISAPP, 2022
2. Variational Autoencoders for 3D Data Processing, Sz. Molnar, L Tamas, ENGINEERING APPLICATIONS OF ARTIFICIAL INTELLIGENCE, (under review), 2022
3. Online learning control for path-aware global optimization with nonlinear mobile robots, T. Sandajudean, L. Busoniu, CONTROL ENGINEERING PRACTIC (accepted), 2022
4. MPI Planar Correction of Pulse Based ToF Cameras, M. Pop, L. Tamas, IEEE International Conference on Automation, Quality and Testing, Robotics, 2022
5. Underwater robot pose estimation using acoustic methods and intermittent position measurements at the surface, M Vicu, L Tamas, L Busoniu, IEEE International Conference on Automation, Quality and Testing, Robotics, 2022
6. REPRESENTATION LEARNING FOR POINT CLOUDS WITH AUTOENCODERS, Sz. Molnar, L. Tamas, IEEE International Conference in Image Processing (under review), 2022
7. Next best view estimation for volumetric information gain, A. Pop, L. Tamas, 6th IFAC Conference on Intelligent Control and Automation Sciences (accepted), 2022
8. Embedded GPU based autonomous robot use cases, Sz. Molnar, L. Tamas, THE 30TH MEDITERRANEAN CONFERENCE ON CONTROL AND AUTOMATION (accepted), 2022
9. D3GATTEN: Dense 3D Geometric Features Extraction Using Self-Attention, B Kelényi, L Tamas, ISSR (under review), 2022
10. Spectral Graph Convolution Networks for Point Cloud Classification, A. Pop, L. Tamas, ISSR (under review), 2022