

**Universitatea Tehnica din Cluj-Napoca,  
Facultatea de Automatica si Calculatoare  
Departamentul Calculatoare**

**PERCEPȚIA MULTI-SCALARĂ ȘI MULTI-MODALĂ A MEDIILOR 3D  
DINAMICE PRIN FUZIUNEA DATELOR DE STEREOVIZINE DENSĂ,  
FLUX OPTIC DENS ȘI ODOMETRIE VIZUALĂ  
(MULTI-SCALE MULTI-MODAL PERCEPTION OF DYNAMIC 3D  
ENVIRONMENTS BASED ON THE FUSION OF DENSE STEREO,  
DENSE OPTICAL FLOW AND VISUAL ODOMETRY INFORMATION)**

Cod proiect: PN-II-ID-PCE-2011-3-1086  
Contract 344 din 01/01/2012

**Raport faza 3 / 2014**

**Director proiect:**

Prof. dr. ing. Sergiu Nedevschi

**Colectiv:**

Conf. dr. ing. Tiberiu Marita,

Conf. dr. ing. Radu Danescu,

Sef lucrari dr. ing. Florin Oniga

Doctorand ing. Andrei Vatavu

Doctorand ing. Marius Drulea

Doctorand ing. Voichita Popescu

Masterand ing. Szilard Mandici

**Cluj-Napoca, Decembrie 2014**

# Raport științific

privind implementarea proiectului in perioada ianuarie – decembrie 2014

**Titlul proiectului: Percepția multi-scalară și multi-modală a mediilor 3D dinamice prin fuziunea datelor de stereovizine densă, flux optic dens și odometrie vizuală.**

## Obiectivele etapei 2014:

1. Metode noi pentru extragerea de trăsături primare dinamice 3D de mare densitate și acuratețe din secvențe de imagini stereo: 1.1. Dezvoltare de modele probabilistice directe și inverse ale senzorilor (A1.4 – final);
2. Metode noi pentru percepție de nivel înalt folosind trăsăturile primare dinamice 3D de mare densitate și acuratețe: 2.1. Implementare, testare, evaluare și rafinare (A2.3)
3. Diseminare rezultate (A3.1 – intermediar)

## Indeplinirea activitatilor prevazute in proiect

### 1. Dezvoltare de modele probabilistice directe și inverse ale senzorilor (SO1.1, SO1.2, SO1.3)

Modelul senzorial reprezinta procesul formarii masuratorilor in lumea fizica [Thr05]. Exista o gama variata de senzori cu caracteristici diferite. In modelul unui sensor trebuie luate in considerare urmatoarele:

- erorile sistematice
- incertitudinile masuratorilor datorate zgomotelor: mediile, deviatiile standard, covariantele

#### 1.1 Modelul direct

Din cauza acestor doua componente, de obicei in robotica modelul senzorial nu este reprezentat printr-o functie deterministica, ci printr-o distributie de probabilitati pentru diferitele valori. In mod formal modelul senzorial poate fi reprezentat prin functia probabilistica:

$$P(z_t | x_t, m) \quad (1)$$

In aceasta ecuatie  $z_t$  reprezinta valoarea masuratorilor,  $x_t$  reprezinta pozitia robotului iar  $m$  reprezinta starea mediului. Acesta se numeste modelul direct (reprezinta verosimilitatea masuratorilor) reprezentand procesul real de masurare..

Teoretic, modelul senzorial depinde de foarte multi parametri precum: culoarea, netezimea suprafetei, reflectia speculara, pozitia relativa fata de robot etc. De aceea, un model perfect este greu de obtinut, majoritatea aplicatiilor iau in considerare proprietatile cele mai semnificative și mai puțin costisitoare de masurat.

Considerand zgomotul Gaussian al masuratorilor, modelul direct se poate formula in felul urmat:

$$P(z_t | x_t, m) = \begin{cases} \eta \cdot N(z_t^*, z_t, \sigma); z_t \leq z_{\max} \\ 0 \end{cases} \quad (2)$$

In aceasta ecuatie  $\eta$  reprezinta o constanta de normalizare, iar  $z_t^*$  este valoarea adevarata care corespunde masuratorii și se calculeaza in functie de pozitia  $x_t$  și  $m$ .  $P$  are o valoare diferita de zero numai in zona active a senzorului numita și ROI (Region of Interest). Functia  $N$  prin distributia normala, reprezinta zgomotul masuratorilor.

## 1.2 Modelul invers

In aplicatiile de robotica insa trebuie sa reprezentam modelul/starea mediului  $m$  in functie de masuratorile  $Z_t$  si pozitia robotului si nu invers. Asta inseamna ca trebuie sa gasim:

$$P(m | x_t, z_t) \quad (3)$$

Prin aceasta ecuatie reprezentam probabilitatile care corespund diferitelor stari ale mediului in functie de pozitia robotului si valoarea masuratorilor. Acest model se numeste modelul invers (posterior) din cauza ca rezultatele se evalueaza invers fata de cum se intampla procesul in realitate. In practica acest model este evaluat in diferite pozitii fata de robot si in consecinta pozitia absoluta a robotului nu mai este necesara. Dupa simplificare evaluand acest model in fiecare pozitie din mediu, relatia intre modelele invers si direct se poate determina prin legea lui Bayes' in felul urmator:

$$P(m | z_t) = \frac{P(z_t | m) \cdot P(m)}{P(z_t)} \quad (4)$$

## 1.3 Modelul invers al senzorului de stereoviziune

In acest capitol se prezinta calcularea modelul direct si invers in cazul reconstructiei stereo. O solutie utilizata in literatura pentru a reprezenta mediul in urma reconstructiei stereo este folosirea hartilor de elevatii.

Pentru a obtine harta de elevatii sau de ocupare a mediului din datele 3D reconstruite prin stereoviziune densa, avem nevoie de modelul invers al senzorului. Modelul invers total  $P(m|x,z)$  se refera la intreaga harta dar din cauza complexitatii de obicei modelul invers este calculat pentru fiecare celula din harta separat. O alta presupunere folosita des este independenta conditionala intre celule. Aceasta presupunere reduce mult numarul de cazuri posibile si permite calculul probabilitatii de ocupare in timp real.

Pornind de la legea lui Bayes putem formula modelul invers general in modul urmator:

$$P(C_i | X, Z) = \frac{P(X, Z | C_i) \cdot P(C_i)}{P(X, Z)} \quad (5)$$

In ecuatia 5,  $C_i$  reprezinta celula  $i$  din harta de elevatii,  $X$  reprezinta pozitia robotului iar  $Z$  reprezinta masuratoarea de la senzor. In cazul reconstructiei stereo dar si la majoritatea altor senzori, pozitia absoluta a robotului nu influenteaza modelul de incertitudini, numai pozitia relativa fata de obiectele din scena [Thr05]. De asemenea probabilitatea neconditionata (prior)  $P(Z)$  poate fi considerata o constanta. Folosind aceste presupuneri obtinem urmatoarea expresie pentru modelul invers:

$$P(C_i | Z) = \alpha \cdot P(Z | C_i) \cdot P(C_i) \quad (6)$$

In ecuatia 6,  $\alpha$  reprezinta o constanta,  $P(Z|C_i)$  reprezinta verosimilitatea masuratorilor sau modelul direct iar  $P(C_i)$  reprezinta probabilitatea neconditionata (prior) de ocupare a celulei  $i$ . Asadar, pentru determinarea modelului invers avem nevoie de modelul direct si de probabilitatea neconditionata de ocupare pentru fiecare celula. Probabilitatea neconditionata a celulei se poate determina prin achizitia mai multor secvente si inregistrarea numarului de puncte care se proiecteaza in fiecare celula. Probabilitatea neconditionata folosind un singur cadru se poate calcula prin:

$$P_{sample}(C_i) = \frac{nr_i}{nr_{total}} \quad (7)$$

In ecuatia 7,  $nr_i$  reprezinta numarul de puncte reconstruite 3D care se proiecteaza in celula  $i$  iar  $nr_{total}$  reprezinta numarul total de puncte reconstruite. Un singur cadru nu furnizeaza cea

mai buna aproximare dar consideran un numar suficient de cadre rezultatul converge catre valoarea adevarata:

$$P(C_i) = \frac{\sum_{j=1}^n P_{sample\_j}(C_i)}{n} \quad (8)$$

In ecuatia 8,  $n$  reprezinta numarul de cadre folosit pentru estimarea probabilitatii neconditionate.

#### 1.4 Modelul direct al sensorului de stereoviziune

Ca sa putem calcula modelul invers in afara de gasirea probabilitatii neconditionate pentru fiecare celula, trebuia gasit si modelul direct. Pentru gasirea acestui model solutia universala se bazeaza pe masuratori efectuate asupra unor obiecte etalon plasate in diferite pozitii si configuratii cunoscute.

Procesul de estimare al modelului direct al sensorului are 2 etape:

- Estimarea modelului in punctele discrete in care sunt pozitionate obiectele etalon,
- Interpolarea modelului pentru restul punctelor.

Exista doua componente in estimarea modelului direct pentru un obiect etalon:

- Gasirea corespondentei intre centrul celulei si media masuratorilor,
- Gasirea modelului Gaussian de probabilitate in punctual determinat de valoarea medie.

Avem nevoie de prima componenta din cauza ca exista posibilitatea ca media masuratorilor sa nu coincida cu centrul celulei in care este plasat obiectul de referinta. Asa cum am specificat, modelul direct de tip Gaussian va fi centrat in punctul determinat de valoarea medie a masuratorilor si dispesia modelului se va calcula din dispersia masuratorilor.

Dupa prelucrarea masuratorilor trebuie sa gasim o metoda care sa descrie modelul direct in intregul spatiu reprezentat. Aceasta este de fapt o problema de regresie.

Pentru a gasi modelul cel mai potrivit care corespunde masuratorilor putem defini o functie de eroare si problema se reduce la minimizarea functiei.

Exista diferite abordari in literatura pentru potrivirea unui model la masuratori precum potrivirea unui model polinomial, regresie logistica sau retele neuronale [Thr05].




Fig. 1: Distributia probabilistica a punctelor reconstruite in jurul pozitiei reale

Putem presupune ca modelul direct al sensorului este o distributie Gaussiană în 3D care proiectată pe o suprafață de coordonate  $x$  și  $z$  devine o distribuție Gaussiană 2D [Man14]. (Fig. 1)

$$P(x, z) = \frac{1}{2\pi\sigma_x\sigma_z\sqrt{1-\rho^2}} \exp\left(-\frac{1}{2(1-\rho^2)}\left[\frac{(x-\mu_x)^2}{\sigma_x^2} + \frac{(z-\mu_z)^2}{\sigma_z^2} - \frac{2\rho(x-\mu_x)(z-\mu_z)}{\sigma_x\sigma_z}\right]\right) \quad (9)$$

Abordarea propusă pentru găsirea modelului direct în cazul sensorului de stereoviziune este sumarizată în figura 2.

Pentru a obține măsurătorile, folosim obiecte standard de o dimensiune care corespunde cu dimensiunile unei celule în harta de elevații. Ca primul pas, marcăm aceste obiecte în imaginile deja rectificate (Figura 3). Executând reconstrucția stereo densă înregistrăm toate punctele 3D obținute corespunzând la fiecare poligon/obiect marcat anterior. Executăm reconstrucția de multe ori cu aceeași configurație de obiecte/poligoane și evaluăm caracteristicile statistice ale punctelor: media, deviația standard și covarianța.

Fiecare incertitudine de obiect astfel obținută este stocată. La final după ce am calculat acești parametri într-un număr semnificativ de poziții în spațiu filtrăm rezultatele și executăm o interpolare trilineară pentru a extinde rezultatele în tot spațiul. Metoda pentru interpolarea trilineară folosită este una bazată pe IDW (Inverse Distance Weighting), numită “Modified Shepard’s Interpolation Method”. Metodele de interpolare folosind date imperfecte diferă în modul în care ponderea măsurătorilor este luată în calcul. La metoda “Modified Shepard’s Interpolation Method” se consideră toate punctele  $x_k$  de coordonate  $x_k$  și  $z_k$  care se află la o distanță mai mică decât  $R$  în jurul punctului de interes în felul următor [She68]:

$$w(x) = \left(\frac{\max(0, R - d(x, x_k))}{Rd(x, x_k)}\right)^2 \quad (10)$$

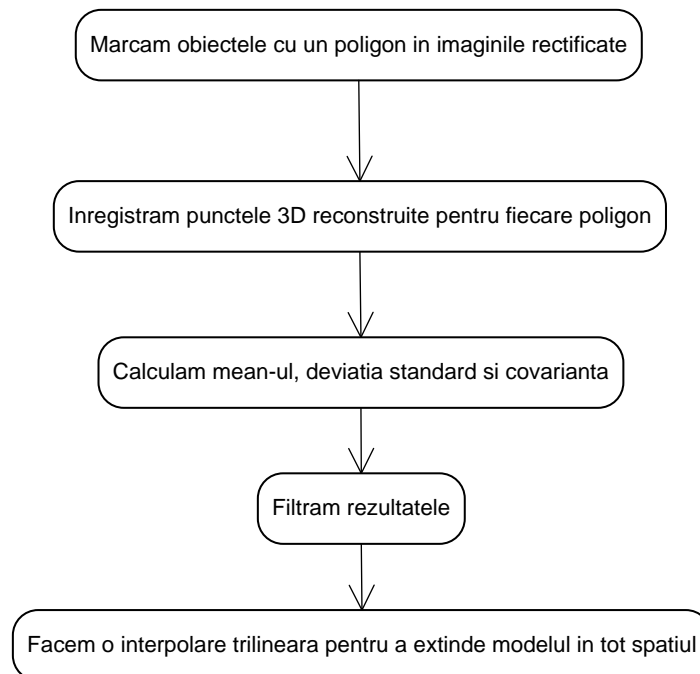


Fig. 2: Algoritmul propus

Această metodă de interpolare a fost modificată folosind o umbrelă imagină pentru fiecare punct. Asta înseamnă că dacă considerăm o măsurătoare, celelalte măsurători care sunt mai

departe de punctul de interes dar au unghiuri polare similare (fata de punctual de interes) nu sunt luate in calcul.

Se face o discretizare a spatiului pentru a reduce atat timpul de rulare cat si memoria necesara pentru Lookup Table-ul care stocheaza rezultatele interpolarii. Gradul de discretizare este de  $10 \times 10 \times 10$  cm care corespunde cu dimensiunile unei celule din harta de elevatii. Interpolarea din ultimul pas este facuta pentru fiecare centru de cuboid in acest spatiu discretizat. Pozitiile masuratorilor sunt interpretate dupa media (meanX, meanY, meanZ) acestora.




Fig. 3: Obiectele standard marcate cu poligoane in imaginea rectificata




Fig. 4: Modelele probabilistice obtinute in diferite pozitii la inaltimea 0

### 1.5 Utilizarea modelului invers al senzorului de stereoviziune pentru construirea hartii de elevatii

In lucrarea [Man14] s-a propus o metoda pentru crearea hartilor de elevatii folosind modelul invers al senzorului de stereoviziune. In acest articol, prin rezultatele obtinute, s-a demonstrat utilitatea unui astfel de model. Harta obtinuta este mai densa decat hartile care se pot obtine prin metodele naive:

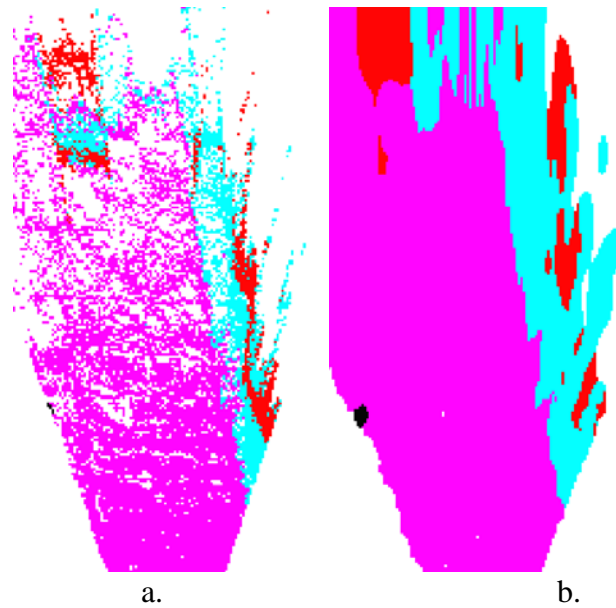


Fig. 5: Harta de elevatii din vedere de sus (culoarea encodeaza inaltimea, culoarea alba reprezinta lipsa informatiilor): a) folosind o metoda naiva [Oni10]; b) folosind modelul invers al reconstructiei [Man14]

De asemenea, prin folosirea unei astfel de metode putem clasifica celulele hartii de elevatii mai robust si cu o acuratete inalta:




Fig. 6: Harta de elevatii reprojectata pe imaginea din dreapta. (portocaliu: drum, galben: trotuar, celelalte culori codifica inaltimea in celula respectiva) [Man14]

### 1.6 Modelele de eroare pentru senzorii de viteza a vehiculului propriu si a vehiculelor urmărite.

Modelele de eroare pentru senzorii de viteza a vehiculului propriu si a vehiculelor urmărite și strategiile lor de determinare urmează același model probabilistic prezentat anterior. Aceste modele sunt dependente de metodele folosite pentru implementarea senzorilor respectiv estimarea vitezelor. Unul dintre elementele cheie în determinarea acestor modele îl reprezintă obținerea măsurătorilor de referință. Pentru achiziția unor măsurători de referință precise s-au utilizat sisteme Novatel GNSS (Global Navigation Satellite System) cu suport RTK (Real Time Kinematic) [Nov13] capabile să furnizeze informații de localizare cu o precizie de până la 0.02m. Astfel, au fost montate unități GNSS atât pe vehiculul propriu (vehiculul pe care se află platforma stereo) cât și pe un vehicul „țintă” (vehicul de test) [Vat14-2]. Poziția de referință a obiectului de test în sistemul local (sistemul de coordonate al vehiculului propriu) s-a calculat știind poziția relativă dintre modulele GNSS instalate pe cele două mașini.



Fig. 7. Achiziția măsurătorilor de referință furnizate de sisteme GNSS de înaltă acuratețe montate pe Vehiculul propriu (vehiculul pe care se află platforma stereo) și pe un vehicul „țintă” (vehicul de test).

Întreg procesul de obținere a măsurătorilor de referință poate fi separat în câteva etape:

1. *Instalarea și configurarea sistemelor pentru cele două vehicule:* antene, module de recepție (receptor mobil Novatel), modem-uri utilizate pentru modularea/demodularea semnalului ce include corecțiile diferențiale transmise, în timp real, de către receptorul de bază (rețeaua de stații fixe a sistemului român de poziționare – ROMPOS), calculatoare dotate cu drivere și interfața software pentru achiziția, stocarea pachetelor de date și controlul receptorilor mobili.

2. *Achiziția secvenței stereo și a datelor de poziționare brute* furnizate de sistemele GNSS. S-a optat pentru achiziția datelor în format GPGGA, format standard ce include informații de localizare, orientare, precizie, timp UTC).

3. *Alinierea off-line a datelor brute cu imaginile achiziționate.* Pentru fiecare pereche de imagini stereo s-a creat un fișier separat cu datele de localizare a celor două vehicule: vehiculul propriu și vehiculul „țintă” (vehiculul urmărit).




Fig.8. Estimarea modelului de eroare pentru trei valori de viteză: 25 km/h (stânga), 31 km/h (mijloc), 35 km/h (dreapta).

Pentru determinarea modelelor de eroare, pentru diferiți algoritmi de implementare a senzorilor de viteză [Gol13], [Vat14-1], [Vat14-2], [Vat12-1], [Vat12-2], [Vat14-3] s-au efectuat experimente în care s-au colectat atât vitezele estimate cât și vitezele de referință furnizate de senzorii GNSS de mare precizie. Modelele de eroare au fost generate pentru un set discret de viteze. Modelul probabilistic continuu de eroare se obține printr-un proces de



interpolare similar celui descris anterior. Pentru senzorul de referință din [Vat13] figura de mai jos prezintă estimarea modelului de eroare pentru trei valori de viteză.

## 2. Implementare, testare, evaluare și rafinare a metodelor de percepție de nivel înalt ce folosesc trăsăturile primare de mare acuratețe (SO2.2)

### 2.1. Implementare, testare, validare și rafinare a metodei de percepție a mediului folosind harta dinamică de înălțimi [Dan14]

Cel mai important scop al unui algoritm de percepție 3D este să reușească să descrie în mod fidel mediul real observat. Pentru a verifica îndeplinirea acestui scop, trebuie să comparăm rezultatele obținute cu o hartă generată cu un senzor care este foarte precis, și are o densitate mare a punctelor măsurate. Din fericire, Karlsruhe Institute of Technology a realizat baza de date KTTI Vision Benchmark Suite, ce conține imagini stereo și date de măsură obținute cu un laserscanner Velodyne, sincronizate împreună. Pentru evaluare, am parcurs următorii pași:

1. Reconstrucție stereo folosind algoritmi proprii, folosind imaginile KTTI
2. Calcul hartă de înălțimi nefiltrată, folosind punctele 3D reconstruite
3. Urmărire folosind harta dinamică de înălțimi propusă
4. Calcul hartă de înălțimi nefiltrată folosind punctele laser Velodyne. Această hartă este considerată harta de referință
5. Calculul diferențelor dintre hărțile obținute prin stereo (nefiltrată și urmărită) și harta de referință.

Au fost calculate următoarele metrici de eroare:

- Procent înălțimi calculate greșit (Badly Computed Heights %, BCH), raportul dintre numărul de înălțimi care diferă față de valoarea de referință cu mai mult de 15 cm și numărul total de înălțimi estimate
- Eroarea medie pătratică (RMSE)
- Densitatea – raportul dintre numărul de celule cu înălțime estimată validă și numărul total de celule din hartă

TABEL I  
ESTIMAREA PERFORMANȚEI LA ESTIMAREA ÎNĂLȚIMI

Hartă de înălțimi	% Densitate	% BCH	RMSE (m)
<i>Nefiltrată</i>	41.12	27.99	0.19
<i>Dinamică, urmărită</i>	60.96	24.19	0.17

Rezultatele sunt prezentate în tabelul I. Se poate observa că estimarea mediului cu harta de înălțimi dinamică reduce procentul BCH și eroarea medie pătratică, mărind în același timp densitatea cu aproape 50%. Aceste rezultate arată că harta urmărită este o descriere mai completă a scenei, cantitatea de informație adăugată venind și cu o creștere a preciziei.

În figura de mai jos se poate observa variația procentului BCH cu distanța. Cum era de așteptat, rata erorilor crește cu distanța, o proprietate intrinsecă a stereoviziunii, dar urmărirea prin harta de înălțimi dinamică îmbunătățește rezultatul.

În afara unei descrieri statice mai precise și mai dense, harta de înălțimi urmărită adaugă informație dinamică acestei hărți. Fiecare celulă are estimată viteza, ca vector cu magnitudine și orientare. Pentru a evalua calitatea estimării vitezei, am folosit secvențe înregistrate în condiții controlate, cu viteze cunoscute. Pentru fiecare cadru, se construiește o histogramă a magnitudinilor vitezelor, astfel încât putem observa mecanismul de convergență a vitezelor estimate la viteza reală a vehiculului. Din aceste histograme, putem apoi produce o estimare a vitezei medii, și o deviație standard a acesteia.




Fig. 9. Variația indicatorului de eroare BCH cu distanța față de vehiculul observator.




Fig. 10. Scenă pentru evaluarea vitezei.

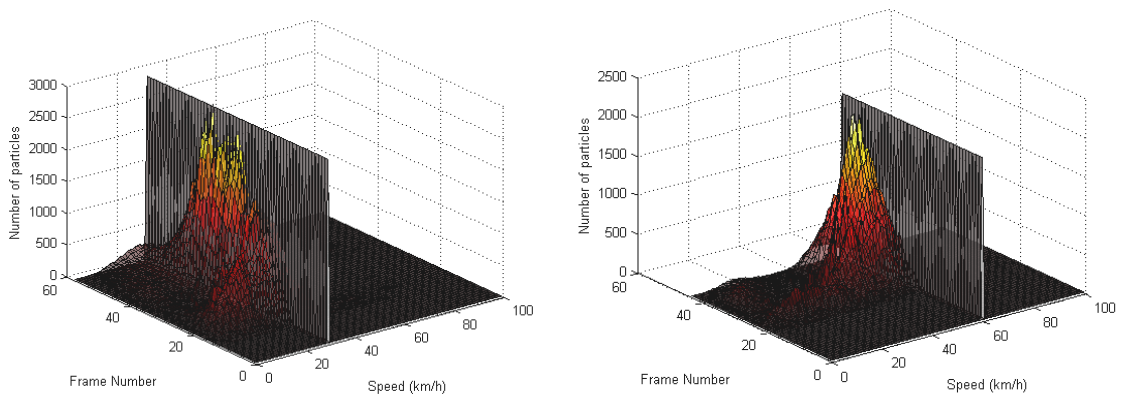


Fig. 11. Histograme de viteză a particulelor pentru scenariul cu vehicul care se apropie.




Fig. 12. Histograme de viteză pentru scenariul cu vehicul care se îndepărtează.

Calitatea estimării vitezei medii a autovehiculului este prezentată în tabelele II și III.

**TABEL II**  
EVALUARE MĂSURĂ VITEZĂ – VEHICUL CARE SE APROPIE

Viteza reală (km/h)	Viteza medie estimată (km/h)	RMSE (km/h)
30	29.2650	1.9720
40	38.9354	3.9316
50	46.9964	6.5184
60	50.0729	11.7318

**TABEL III**  
EVALUARE MĂSURĂ VITEZĂ – VEHICUL CARE SE ÎNDEPĂRTEAZĂ

Viteza reală (km/h)	Viteza medie estimată (km/h)	RMSE (km/h)
30	29.6231	1.6149
40	37.8779	2.6842
50	45.2310	4.9515
60	53.1327	8.2875

## 2.2. Implementare, testare, validare și rafinare a metodei de percepție a mediului folosind linii poligonale dinamice

Arhitectura sistemului de percepție a mediului folosind linii poligonale dinamice (Fig. 13) poate fi separată în două etape principale: *Preprocesare* și *Urmărirea Obiectelor*. Nivelul de *Preprocesare* include operațiile de bază, precum procesarea stereo, calculul hărții de elevație primară, și extragerea conturilor elementare. Nivelul de *Urmărire a Obiectelor* constă în estimarea stării optime pentru fiecare obiect individual. În primul rând, se aplică o asociere a datelor pentru asignarea noilor măsurători la obiectele urmărite sau pentru inițializarea unor noi candidați. Apoi, pentru fiecare model țintă se efectuează o serie de pași ca: predicția stării, ponderarea particulelor, actualizarea geometriei, re-eșantionare și injecție de ipoteze noi.

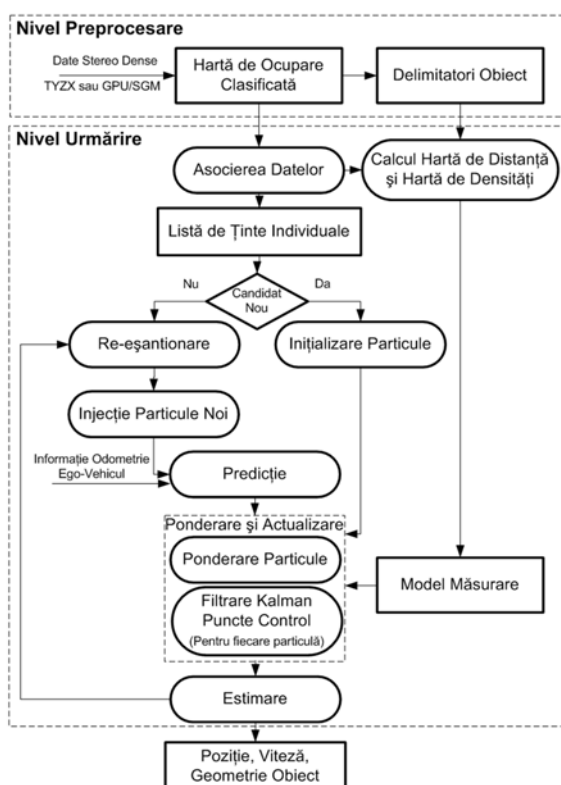


Fig. 13. Arhitectura sistemului de urmărire a obiectelor bazat pe modele poligonale flexibile și filtru de particule Rao-Blackwellized. [Vat14-2]

Fiecare obiect din scenă este descris de un vector de stare compus din poziția unui punct central  $P_{ref}$ , un vector de viteză atașat acestui punct central, și o serie de puncte de control  $P_c$  care descriu conturul obiectului, permițând acestuia să se deformeze.




Fig. 14. Modelul obiectelor [Vat13]

Starea obiectelor este estimată prin intermediul unui filtru de particule Rao-Blackwellized. Un dezavantaj al metodei clasice de filtrare bazată pe particule este faptul că aceasta nu este potrivită pentru stările de dimensiuni mari. De obicei, complexitatea computațională crește exponențial odată cu numărul de parametri de stare. Procesul “Rao-Blackwellization” constă în estimarea analitică a unei părți a stării, reducând astfel numărul de ipoteze necesare, în mod normal, de un filtru de particule pentru a acoperi întreg spațiul de combinații.

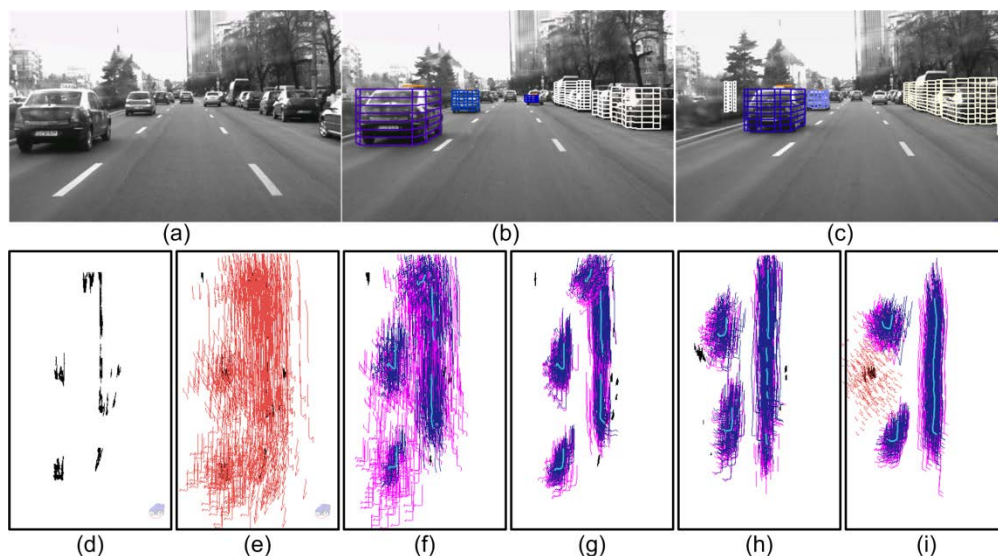


Fig. 15. Urmărirea prin contur a obiectelor din trafic. Se observă particulele candidate, și conturul estimat pe baza particulelor.

Pentru fiecare obiect țintă individual soluția de urmărire propusă poate fi descompusă într-o secvență de pași. În prima etapă, pentru fiecare particulă se determină câte o pondere în funcție de cât de bine se potrivește cu noile observații. Aceasta este suficient pentru a furniza poziția și viteza estimată. În cea de-a doua etapă, pentru fiecare particulă, pozițiile punctelor sale de control sunt actualizate cu noile observații (puncte de control extrase de pe delimitatorii de la cadrul curent). Procedura de actualizare se face la nivelul fiecărui punct de control prin aplicarea a câte un filtru Kalman 2x2. Astfel, având populația de ipoteze, ponderi

asignate și puncte de control actualizate cu noile măsurători, parametrii de stare sunt estimați folosind suma ponderată a tuturor ipotezelor ce aproximează distribuția de probabilitate a obiectului țintă.

Pentru evaluarea sistemului de urmărire bazat pe contururi, primul set de experimente s-a bazat pe folosirea imaginilor furnizate de baza de date de referință KITTI. Au fost testați următorii algoritmi: urmărirea bazată pe cuboide utilizând filtre Kalman, urmărirea bazată pe filtre de particule urmată de gruparea celulelor în obiecte individuale, urmărirea poziției și geometriei modelelor poligonale folosind filtre Kalman și urmărirea poziției și geometriei modelelor poligonale folosind filtre de particule Rao-Blackwellized (RBPF-ICP). Rezultatele sunt prezentate în tabelele IV și V [Vat14-2].

TABEL IV. Comparație privind Acuratețea de Estimare a Vitezei Obiectelor

Metoda	OBIECTE VIZIBILE TOTAL		OBIECTE VIZIBILE PARȚIAL	
	MAE (km/h)	STDEV (km/h)	MAE (km/h)	STDEV (km/h)
CUBOIDE	2.54	2.63	3.78	4.10
PF-GRID	1.88	1.65	3.96	3.07
KF-ICP	2.59	1.18	3.55	2.56
RBPF-ICP*	1.90	1.31	2.45	2.55

TABEL V. Comparație privind Acuratețea de Estimare a Orientării Obiectelor

Metoda	OBIECTE VIZIBILE TOTAL		OBIECTE VIZIBILE PARȚIAL	
	MAE (deg)	STDEV (deg)	MAE (deg)	STDEV (deg)
CUBOIDS	5.77	4.94	9.12	5.70
PF-GRID	4.57	4.70	8.95	1.84
KF-ICP	4.54	2.92	7.72	3.70
RBPF-ICP	3.72	2.65	5.49	2.56

O altă abordare pentru testarea sistemului de urmărire se bazează pe utilizarea unor sisteme DGPS de înaltă precizie, Novatel GNSS (Global Navigation Satellite System) cu suport RTK (Real Time Kinematic), capabile să furnizeze informații de localizare cu o precizie de până la 0.02m. Astfel, o unitate GNSS a fost montată pe un vehicul „țintă” iar alte două unități au fost montate pe vehiculul propriu (vehiculul pe care se află platforma stereo). Poziția de referință a obiectului de test în sistemul local (sistemul de coordonate al vehiculului propriu) s-a calculat știind poziția relativă dintre modulele GNSS instalate pe cele două mașini.




Fig. 16. Scenariu de trafic cu vehiculul propriu și cel urmărit

Fig. 17, 18, și 19 prezintă rezultatele estimate pentru o scenă reală de trafic urban, folosind algoritmul urmărire pe baza modelelor poligonale variabile și filtrul de particule Rao-Blackwellized (RBPF-ICP). Testele sunt realizate pentru o porțiune de secvență ce cuprinde 270 cadre (la 10 cadre pe secundă) în care vehiculul „țintă” este urmărit prin câteva manevre, la o distanță între 10 și 25 de metri. Viteza „țintei” variază de la 10 la 40 km/h, iar orientarea „țintei” relativă la sistemul de coordonate al vehiculului propriu se schimbă odată ce se execută un viraj la stânga. Viteza estimată este comparată cu viteza de referință obținută cu ajutorul dispozitivelor GNSS. Eroarea medie absolută obținută în estimarea vitezei a fost de 1.85 km/h.

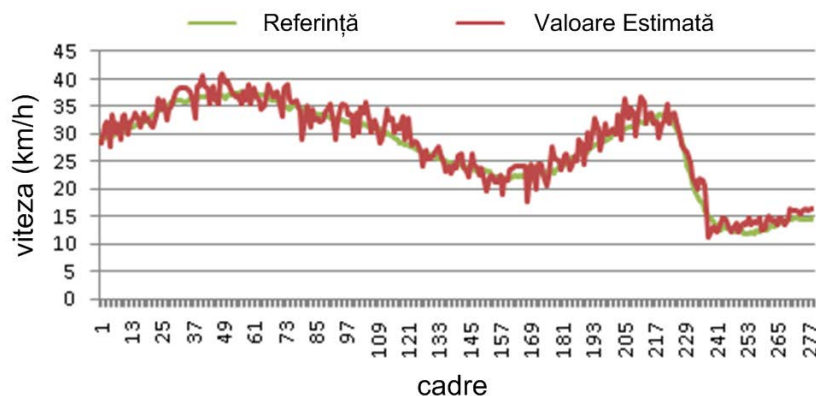


Fig. 17. Viteza estimată (roșu) vs. viteza de referință (verde) [Vat14-2].

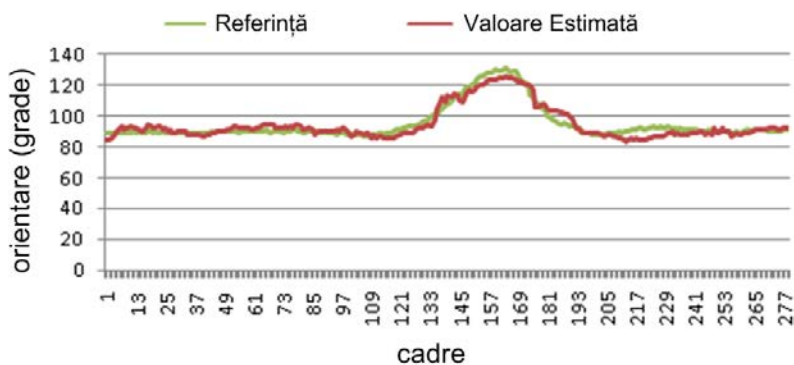


Fig. 18. Orientarea estimată a „țintei” (roșu) cu algoritmul RBPF-ICP vs. orientarea de referință (verde) [Vat14-2].

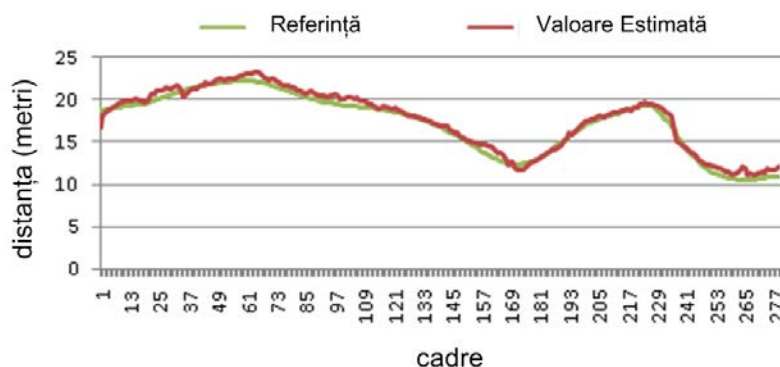


Fig. 19. Distanța estimată a vehiculului urmărit față de vehiculul propriu. Valoarea estimată cu algoritmul RBPF-ICP (roșu) vs. valoarea de referință (verde)[Vat14-2].

### **3. Diseminare rezultate (O3 Diseminare rezultate)**

#### **Lucrări elaborate și publicate sau înaintate spre publicare de colectivul proiectului în perioada ianuarie – decembrie 2014**

##### **Lucrări în jurnale cotate ISI:**

1. R. Danescu, S. Nedevschi, "A Particle-Based Solution for Modeling and Tracking Dynamic Digital Elevation Maps", *IEEE Transactions on Intelligent Transportation Systems*, 2014, Volume: 15 Issue: 3 Pages: 1002-1015.
2. V. Popescu, S. Nedevschi, R. Danescu, T. Marita, "A Lane Assessment Method Using Visual Information Based on a Dynamic Bayesian Network", *Journal of Intelligent Transportation Systems: Technology, Planning, and Operations*, publicat online în 2014.
3. A. Vatavu, R. Danescu, S. Nedevschi, "Stereovision-Based Multiple Object Tracking in Traffic Scenarios using Free-Form Obstacle Delimiters and Particle Filters", acceptat în *IEEE Transactions on Intelligent Transportation Systems*, 2014.

##### **Lucrări la conferințe**

1. A. Costea, S. Nedevschi, "Word Channel Based Multiscale Pedestrian Detection Without Image Resizing and Using Only One Classifier", *Proceedings of 2014 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pp. 2393-2400, 2014.
2. A. Costea, S. Nedevschi, "Multi-Class Segmentation for Traffic Scenarios at Over 50 FPS", *Proceedings of 2014 IV Symposium, Dearborn, USA, 2014*, pp. 1390-1395.
3. I. Giosan, S. Nedevschi, "Superpixel-based Obstacle Segmentation from Dense Stereo Urban Traffic Scenarios Using Intensity, Depth and Optical Flow Information", acceptat în *IEEE Intelligent Transportation Systems Conference 2014 (ITSC 2014)*, October 8-11, Qingdao, China.
4. A. Vatavu, R. Danescu, S. Nedevschi, "Modeling and Tracking of Crowded Traffic Scenes by using Policy Trees, Occupancy Grid Blocks and Bayesian Filters", acceptat în *IEEE Intelligent Transportation Systems Conference 2014 (ITSC 2014)*, October 8-11, Qingdao, China.
5. A. Iloie, I. Giosan, S. Nedevschi, "UV disparity based obstacle detection and pedestrian classification in urban traffic scenarios", in *IEEE International Conference on Intelligent Computer Communication and Processing*, September 4-6, Cluj-Napoca, Romania, 2014, pp. 119-125.
6. S. Mandici, S. Nedevschi, "Aggregate Road Surface based Environment Representation using Digital Elevation Maps", in *IEEE International Conference on Intelligent Computer Communication and Processing*, September 4-6, Cluj-Napoca, Romania, 2014, pp. 149-156.
7. C. Golban, S. Nedevschi, "Moving rigid objects segmentation in 3D dynamic traffic scenes using a stereovision system", in *IEEE International Conference on Intelligent Computer Communication and Processing*, September 4-6, Cluj-Napoca, Romania, 2014, pp. 165-170.
8. I. Giosan, S. Nedevschi, "Multi-feature Real Time Pedestrian Detection from DenseStereo SORT-SGM Reconstructed Urban Traffic Scenarios", in *International Conference on Computer Vision Theory and Applications (VISAPP 2014)*, Lisbon, Portugal, 2014.
9. S. Nedevschi, T. Marita, R. Danescu, F. Oniga, A. Vatavu, M. Drulea, "Multi-scale, multi-modal perception of dynamic 3D environment based on the fusion of dense

stereo, optical flow and virtual odometry information”, Romanian Research Convention, Inventions and Innovations Show - Inventika 2014, Bucharest, October 15-18, 2014.

10. S. Nedevschi, “Stereovision based perception for driving assistance and autonomous driving”, Symposium Technical University of Cluj-Napoca – Technical University of Braunschweig, Braunschweig, October 20, 2014

### **Capitol de carte**

1. A. Vatavu and S. Nedevschi, "Vision Based Motion Estimation of Obstacles in Dynamic Unstructured Environments", Informatics in Control, Automation and Robotics, Lecture Notes in Electrical Engineering (LNEE), Volume 283, Springer International Publishing, pp. 235-249, 2014.

### **Teze de doctorat**

1. I.Giosan – Contributii la Detectia si Recunoasterea Obstacolelor in Scene de Trafic folosiind Stereoviziunea, 2014.
2. A.Vatavu – Metode de Reprezentare si Urmarire in Scenele de Trafic, 2014
3. R. Brehar - Adaptive Search Space Pruning in the Context of Multiple Attitude Pedestrian Detection Models, 2014
4. M. Negru - Image Pre-Processing Solutions for Driving Assistance in Adverse Weather Conditions, 2014.

### **Referinte**

[Man14] S. Mandici, S. Nedevschi : “Aggregate Road Surface based Environment Representation using Digital Elevation Maps” Intelligent Computer Communication and Processing (ICCP), 2014 IEEE International Conference, Sept. 2014, 149-156.

[She68] D. Shepard, "A two-dimensional interpolation function for irregularly-spaced data". "Proceedings of the 1968 ACM National Conference". 1968, pp. 517–524.

[Thr05] S. Thrun , W. Burgard , Dieter Fox, Probabilistic Robotics (Intelligent Robotics and Autonomous Agents), The MIT Press, 2005.

[Oni10] F. Oniga, S. Nedevschi, "Processing Dense Stereo Data Using Elevation Maps: Road Surface, Traffic Isle and Obstacle Detection", IEEE Transactions on Vehicular Technologies, 2010, pp. 1172-1182.

[Gol13] C. Golban, S. Nedevschi, "Speed estimation for scene objects using stereo visual odometry", in Proceedings of IEEE International Conference on Intelligent Computer Communication and Processing, 5-7 September, Cluj-Napoca, Romania, 2013, pp. 91-94.

[Nov13] NovaTel Inc., “High Precision GPS & GNSS receivers”, online at <http://www.novatel.com/products/gnss-receivers/> , Accesat, 11 Decembrie, 2013.

[Vat14-1] A. Vatavu, R. Danescu, and S. Nedevschi, "Modeling and Tracking of Crowded Traffic Scenes by using Policy Trees, Occupancy Grid Blocks and Bayesian Filters", in Proceedings of 17th International IEEE Conference Intelligent Transportation Systems (ITSC 2014), Chingdao, China, October 9-11, 2014, pp. 1948 - 1955.

[Vat14-2] A. Vatavu, R. Danescu, and S. Nedevschi, "Stereovision-Based Multiple Object Tracking in Traffic Scenarios using Free-Form Obstacle Delimiters and Particle Filters", IEEE Transactions on Intelligent Transportation Systems, accepted for publication - October 2014, DOI: 10.1109/TITS.2014.2366248.



[Vat12-1] A. Vatavu, R. Danescu, S. Nedevschi, "Real-time dynamic environment perception in driving scenarios using difference fronts", 2012 IEEE Intelligent Vehicles Symposium (IV 2012), June 2012, Alcalá de Henares, Madrid, Spain, June 3-7, 2012, pp. 717-722, DOI: 10.1109/IVS.2012.6232270

[Vat12-2] A. Vatavu and S. Nedevschi, "Vision based Real-time Modeling of Dynamic Unstructured Environments in Driving Scenarios", in Proc. of the 9th International Conference on Informatics in Control, Automation and Robotics (ICINCO 2012), SciTePress, Volume 2, Rome, Italy, July 28 - 31, 2012, pp.141-149.

[Vat12-3] A. Vatavu, S. Nedevschi, "Real-time modeling of dynamic environments in traffic scenarios using a stereo-vision system", 2012 15th International IEEE Conference on Intelligent Transportation Systems (ITSC 2012), Sept. 16-19, Anchorage, Alaska, USA, 2012, pp.722-727, DOI: 10.1109/ITSC.2012.6338820.

[Vat13] A. Vatavu, R. Danescu, and S. Nedevschi, "Tracking Multiple Objects in Traffic Scenarios Using Free-Form Obstacle Delimiters and Particle Filters", in Proceedings of 16th International IEEE Conference Intelligent Transportation Systems (ITSC 2013), The Hague, The Netherlands, October, 2013, pp. 1346-1351, DOI: 10.1109/ITSC.2013.6728418

[Dan14] R. Danescu, S. Nedevschi, "A Particle-Based Solution for Modeling and Tracking Dynamic Digital Elevation Maps", IEEE Transactions on Intelligent Transportation Systems, 2014, Volume: 15 Issue: 3 Pages: 1002-1015.