

Radu Dănescu

Percepția prin particule



**Editura UTPRESS
Cluj-Napoca, 2019
ISBN 978-606-737-344-8**



Editura U.T. PRESS
Str. Observatorului nr. 34
C.P. 42, O.P. 2, 400775 Cluj-Napoca
Tel.:0264-401.999
e-mail: utpress@biblio.utcluj.ro
<http://biblioteca.utcluj.ro/editura>

Director: Ing. Călin D. Câmpean

Recenzia: Conf.dr.ing. Florin Oniga
Conf.dr.ing. Tiberiu Marița

Copyright © 2019 Editura U.T.PRESS

Reproducerea integrală sau parțială a textului sau ilustrațiilor din această carte este posibilă numai cu acordul prealabil scris al editurii U.T.PRESS.

ISBN 978-606-737-344-8

Cuprins

Introducere	5
I. Tehnici de urmărire	6
1. Urmărirea ca inferență probabilistică.....	6
1.1. Model dinamic	6
1.2. Predicție	7
1.3. Modelul de măsură și asocierea datelor	7
1.4. Actualizarea stării (corecția)	8
1.5. Problemele care apar, și nevoie de aproximare	9
2. Filtrul Kalman, inferența potrivită pentru densități Gaussiene	9
2.1. Predicția filtrului Kalman	10
2.2. Asocierea datelor pentru filtrul Kalman	10
2.3. Actualizarea stării prin filtrul Kalman	11
2.4. Problemele filtrului Kalman	11
3. Filtrarea bazată pe particule, soluția pentru problemele non-Gaussiene	11
3.1. Algoritmul CONDENSATION – reeșantionarea	12
3.2. Algoritmul CONDENSATION - predicția	14
3.3. Algoritmul CONDENSATION - actualizarea	15
3.4. Algoritmul CONDENSATION - estimarea.....	17
4. Bibliografie	17
II. Detecția și urmărirea benzilor de circulație folosind filtrele de particule	18
1. Introducere	18
2. Soluția pe scurt.....	19
3. Descrierea algoritmului de urmărire	21
3.1. Particulele benzilor de circulație.....	21
3.2. Predicția	22
3.3. Detecția unghiului de aplecare.....	23
3.4. Proiecția particulelor în spațiul de măsură.....	26
3.5. Indiciile vizuale.....	27
3.6. Ponderarea particulelor prin măsurătoare	28
3.7. Validarea rezultatului.....	29
4. Teste și rezultate	31
4.1. Comparatie cu filtrul Kalman	31
4.2. Evaluarea acurateții estimării unghiului de aplecare.....	33
4.3. Evaluarea performanței pe scenariu de autostradă.....	33
4.4. Evaluarea performanței în scenariu urban	35

4.5. Un model experimental: banda cu lățime variabilă liniar	37
4.6. Performanța de timp.....	37
5. Concluzii	38
6. Bibliografie	38
III. Urmărirea obiectelor folosind particulele	40
1. Introducere	40
2. Vedere de ansamblu asupra soluției.....	40
3. Modelul obiectelor	44
4. Datele de măsură.....	46
5. Ponderarea particulelor folosind măsurătoarea.....	47
6. Teste și rezultate	50
7. Concluzie și posibile extensii.....	53
8. Bibliografie	53
IV. Folosirea particulelor pentru modelarea și urmărirea hărților de ocupare.....	55
1. Introducere	55
2. Modelul lumii.....	58
3. Algoritmul pe scurt	59
4. Predicția	59
5. Modelul de măsură.....	61
5.1. Incertitudinea măsurătorilor stereo	61
5.2. Indiciul densității hărții binare de ocupare.....	62
5.3. Tratarea ocluziilor	63
5.4. Indiciul distanței față de măsurătoare	64
6. Ponderare și reeșantionare	66
6.1. Ponderarea particulelor	66
6.2. Reeșantionarea particulelor.....	67
7. Inițializarea particulelor	69
8. Estimarea stării celulelor și extragerea obiectelor individuale	69
9. Teste și rezultate	71
9.1. Evaluare calitativă.....	71
9.2. Evaluare numerică în medii controlate	74
10. Concluzii și perspective	76
11. Bibliografie	77
V. Utilizarea particulelor pentru urmărirea hărților dinamice de înălțimi	80
1. Introducere	80
2. Harta de înălțimi dinamică bazată pe particule.....	82
3. Vedere de ansamblu asupra soluției.....	85

4. Descrierea algoritmului.....	87
4.1. Deplasarea și difuzia particulelor.....	87
4.2. Datele de măsură: harta primară de înălțimi	89
4.3. Compensarea unghiului de aplecare	90
4.4. Calculul ponderilor înălțimilor, și ponderarea particulelor.....	91
4.5. Reșantionare	94
4.4. Crearea particulelor noi.....	95
4.5. Estimare și vizualizare	95
5. Teste și rezultate	96
5.1. Evaluarea acurateții reconstrucției scenei	96
5.2. Evaluarea acurateții de estimare a vitezelor	99
5.3. Evaluare calitativă.....	102
5.4. Comparație a modurilor de reprezentare a lumii	104
6. Concluzii și perspective	105
7. Bibliografie	106
Mulțumiri	109

Introducere

Sistemele robotice autonome devin tot mai prezente în viața noastră. Roboți care efectuează sarcini limitate în fabrici înalt automatizate, roboți pentru explorarea planetelor îndepărtate, roboți sau drone cu scop militar, sau autovehicule care se conduc singure, toate acestea au în comun capacitatea de a lua decizii fără a implica utilizatorul uman. Deciziile, luate de diferiți algoritmi de control, se bazează în primul rând pe înțelegerea situației în care robotul se află.

Înțelegerea cât mai bună a situației de către robotului autonom implică preluarea, filtrarea și interpretarea datelor provenite de la senzorii cu care robotul este echipat. Vom numi procesul de transformare a datelor senzoriale în parametri constituenți ai situației robotului percepție. Percepția va ține cont de caracteristici ale senzorilor precum limitele și erorile acestora, și de informații cunoscute anterior despre mediul urmărit, precum modelul matematic al suprafeței terenului parcurs sau modelele de mișcare ale obiectelor din scenă.

Percepția implică extragerea informației utile din datele senzoriale, și eliminarea pe cât posibil a zgomotului. Un singur senzor poate oferi mai multe tipuri de date. Unii senzori produc în mod direct date care exprimă în mod direct starea lumii 3D, precum distanța sau viteza. Alți senzori au nevoie de procesare suplimentară pentru extragerea informației utile. În această situație sunt senzorii de tip cameră video, monoculari sau multi-oculari. Senzorii video oferă o mare cantitate de date, din care se pot extrage distanțe, dimensiuni, orientări, clase de obiecte, culori, și multe altele. În același timp, senzorii video introduc mult zgomot, sau informație eronată datorată iluziilor optice sau limitărilor algoritmilor de extragere a trăsăturilor.

Datele senzoriale sunt uneori complementare, altele în conflict. Fiecare senzor are punctele lui tari și punctele lui slabe, iar un sistem de percepție trebuie să țină cont de aceste caracteristici pentru a obține estimarea optimă. Un mod de a elimina datele senzoriale eronate este de a impune constrângeri asupra stării estimate, constrângeri derivate din cunoștințele anterioare pe care le avem despre scenă, cunoștințe care includ geometria scenelor observate și legi ale fizicii. Constrângerile pot fi aplicate la nivel de instantaneu, sau pot să fie aplicate evoluției stării în timp. Tot în timp se pot acumula și informațiile derivate din datele senzoriale, sub presupunerea că mediul observat nu se schimbă brusc.

Percepția bazată pe procesarea în timp a informațiilor senzoriale, pentru a obține în fiecare moment o estimare optimă a stării mediului înconjurător mai este cunoscută și sub numele de urmărire. În procesul de urmărire se întâlnesc informațiile estimate în trecut despre o anumită stare cu datele preluate de la senzori în prezent și cu cunoștințele generale despre sistemul observat. Toate aceste informații au incertitudini, și din acest motiv estimarea este de fapt un calcul al probabilităților, în loc să fie un calcul exact al unor valori. Există mai multe abordări pentru inferența probabilistică în domeniul urmăririi, cele mai populare fiind filtrul Kalman și filtrul bazat pe particule.

Filtrele bazate pe particule sunt tehnici de tip Monte Carlo, prin care se rezolvă probleme de estimare pe baza generării și verificării unor ipoteze aleatoare. În acest volum sunt prezentate mai multe aplicații ale filtrelor de particule, pentru percepția diferitelor elemente de interes din traficul auto. Sunt prezentate tehnici pentru urmărirea benzilor de circulație, pentru urmărirea obstacolelor, sau pentru urmărirea întregii scene sub forma hărților de ocupare sau a hărților de înălțimi. În fiecare caz se prezintă o altă abordare a filtrelor bazate pe particule, astfel încât cititorul va avea o imagine de ansamblu asupra proiectării și aplicării acestor filtre pentru probleme diverse de percepție.

I. Tehnici de urmărire

1. Urmărirea ca inferență probabilistică

Cu toate că nu există o definiție universală a procesului de urmărire (tracking), putem să îl privim ca fiind procesul de raționare asupra stării unei entități care evoluează în timp, pe baza unei secvențe de observații. În mod particular, urmărirea benzilor de circulație se poate defini ca procesul de raționare asupra poziției și geometriei benzii pe baza unor trăsături extrase din imagini, și urmărirea obiectelor se poate defini ca procesul de raționare asupra poziției și dimensiunii obiectelor pe baza informațiilor oferite de senzori 3D (cum sunt informațiile 3D obținute prin stereoviziune).

O introducere excelentă în problematica urmăririi văzută ca proces de inferență probabilistică poate fi găsită în [1]. Pornind de la acest material, vom prezenta o scurtă descriere a formalismului matematic al procesului de urmărire.

Starea entității urmărite, într-un cadru (moment al unei măsurători, mai ales bazate pe imagini) i , se poate descrie printr-o variabilă aleatoare \mathbf{X}_i . Astfel, în loc să avem o valoare definită pentru stare, vom avea o mulțime de valori posibile, și o densitate de probabilitate asociată care ne va spune ce valori sunt mai probabile a fi corespunzătoare stării reale.

Măsurătoarea în cadrul i este descrisă prin variabila aleatoare \mathbf{Y}_i . Acest lucru ne spune că există mai multe indicii disponibile, sau o mulțime continuă de trăsături, și putem să definim o funcție densitate de probabilitate pentru această mulțime.

Scopul urmăririi ca inferență probabilistică este de a evalua $P(\mathbf{X}_i | \mathbf{Y}_0 = y_0, \dots, \mathbf{Y}_i = y_i)$, adică de a calcula densitatea de probabilitate condiționată a stării \mathbf{X}_i pe baza secvenței de măsurători din trecut și din cadrul curent.

Datorită faptului că de multe ori procesul de urmărire trebuie să producă rezultate după fiecare cadru (urmărire în timp real), și pentru că un sistem de urmărire trebuie să funcționeze în mod continuu pentru o perioadă nedefinită de timp, estimarea lui $P(\mathbf{X}_i | \mathbf{Y}_0 = y_0, \dots, \mathbf{Y}_i = y_i)$ trebuie să fie realizată într-o manieră recursivă, astfel încât rezultatele din cadrul anterior să poată fi utilizate în estimarea din cadrul curent. Pentru a putea realiza acest lucru, se definesc următoarele concepte:

1.1. Model dinamic

Un sistem dinamic bine definit se comportă într-un mod predictibil, sub imperiul unor ecuații de mișcare (sau de evoluție generală în timp). Un sistem complet imprevizibil evoluează într-o manieră aleatorie, dar chiar și în acest caz aleatoriul poate fi limitat la un domeniu finit, sau poate să fie supus unei distribuții de probabilitate. Majoritatea sistemelor au o parte predictibilă și o parte aleatorie, și ele împreună guvernează evoluția sistemului în timp. Indiferent cât de previzibil sau imprevizibil este sistemul, putem defini modelul dinamic ca $P(\mathbf{X}_i | \mathbf{X}_{i-1})$ - probabilitatea ca sistemul să ajungă într-o stare cu valoarea \mathbf{X}_i pe baza stării anterioare \mathbf{X}_{i-1} .

Modelul dinamic descrie în mod complet densitatea de probabilitate a stării curente condiționată de stările trecute, dar asta doar dacă se consideră adevărată o importantă presupunere simplificatoare, și anume că doar trecutul imediat contează:

$$P(\mathbf{X}_i | \mathbf{X}_1, \dots, \mathbf{X}_{i-1}) = P(\mathbf{X}_i | \mathbf{X}_{i-1}) \quad (1)$$

Simplificarea de mai sus nu este, de fapt, foarte restrictivă. Dacă parametrii de stare sunt aleși cu atenție, trecutul poate fi codificat în starea curentă. De exemplu, când se urmărește poziția unui obiect, dacă viteza și accelerația acestuia sunt incluse în starea curentă acest lucru poate spune destul de multe despre pozițiile lui trecute.

1.2. Predicție

Măsurătorile din trecut și modelul dinamic ne permit să inferăm valorile de probabilitate ale stării curente, înainte ca datele senzoriale (măsurătorile) să fie procesate. În mod formal, predicția poate să fie definită ca $P(\mathbf{X}_i | \mathbf{Y}_0 = y_0, \dots, \mathbf{Y}_{i-1} = y_{i-1})$ - densitatea de probabilitate condiționată a stării curente dacă se știu măsurătorile trecute.

Dacă folosim presupunerea că doar trecutul imediat contează, valorile de probabilitate ale predicției se pot calcula recursiv, pe baza rezultatelor trecute și a modelului dinamic:

$$P(\mathbf{X}_i | y_0, \dots, y_{i-1}) = \int P(\mathbf{X}_i | \mathbf{X}_{i-1}) P(\mathbf{X}_{i-1} | y_0, \dots, y_{i-1}) d\mathbf{X}_{i-1} \quad (2)$$

Pentru o mai bună înțelegere a ecuației de mai sus, este necesară o explicație intuitivă. Rezultatul estimării din trecut, $P(\mathbf{X}_{i-1} | y_0, \dots, y_{i-1})$, este o funcție de densitate de probabilitate, ceea ce înseamnă că pentru fiecare valoare posibilă a vectorului de stare există un număr care descrie cât de aproape de realitate această stare este. Pentru a obține predicția stării curente, fiecare “bucățică” de stare trecută este procesată prin modelul dinamic, și rezultatele sunt “adunate” într-o nouă funcție de densitate de probabilitate. Aceasta este semnificația integralei pe domeniul lui \mathbf{X}_{i-1} . Deja devine evident că problema urmăririi nu este simplă.

În absența datelor de măsură din cadrul curent, funcția de densitate de probabilitate obținută prin predicție $P(\mathbf{X}_{i-1} | y_0, \dots, y_{i-1})$ este cea mai bună evaluare a stării entității urmărite pe care noi o putem avea la momentul actual. Când măsurătorile devin disponibile, predicția ajută sistemul în procesul de asociere a datelor, și ajută la filtrarea rezultatelor în procesul de actualizare.

1.3. Modelul de măsură și asocierea datelor

În fiecare cadru i pot fi mai multe măsurători disponibile, și există posibilitatea ca nu toate să fie utile. Dacă notăm cu y_i^r măsurătoarea r a cadrului i , probabilitatea ca această măsurătoare să fie utilă pentru urmărirea stării entității date se notează ca $P(\mathbf{Y}_i = y_i^r | y_0, \dots, y_{i-1})$ - dându-se măsurătorile din trecut asociate cu această entitate, cât de verosimilă este măsurătoarea y_i^r . Această probabilitate se poate calcula recursiv ca:

$$P(\mathbf{Y}_i = y_i^r | y_0, \dots, y_{i-1}) = \int P(\mathbf{Y}_i = y_i^r | \mathbf{X}_i, y_0, \dots, y_{i-1}) P(\mathbf{X}_i | y_0, \dots, y_{i-1}) d\mathbf{X}_i \quad (3)$$

Pentru ca problema să devină rezolvabilă, se face o nouă presupunere simplificatoare, și anume că o măsurătoare este independentă condițional de celelalte măsurători, dându-se starea \mathbf{X}_i . Acest lucru poate fi scris ca:

$$P(\mathbf{Y}_i, \mathbf{Y}_j, \dots, \mathbf{Y}_k | \mathbf{X}_i) = P(\mathbf{Y}_i | \mathbf{X}_i)P(\mathbf{Y}_j, \dots, \mathbf{Y}_k | \mathbf{X}_i) \quad (4)$$

Folosind această presupunere simplificatoare, probabilitatea ca o anumită măsurătoare să fie legată de starea obiectului urmărit se scrie ca:

$$P(\mathbf{Y}_i = y_i^r | y_0, \dots, y_{i-1}) = \int P(\mathbf{Y}_i = y_i^r | \mathbf{X}_i)P(\mathbf{X}_i | y_0, \dots, y_{i-1})d\mathbf{X}_i \quad (5)$$

În ecuația de mai sus avem doi termeni care, combinați, ne dau probabilitatea gradului de utilitate a lui y_i^r . Al doilea termen este predicția, deja calculată, care descrie starea curentă pe baza măsurătorilor anterioare. Primul termen este o instanță a mai generalului $P(\mathbf{Y}_i | \mathbf{X}_i)$, care descrie densitatea de probabilitate condiționată pe toată mulțimea posibilelor valori ale măsurătorilor, dându-se starea \mathbf{X}_i .

Astfel, $P(\mathbf{Y}_i | \mathbf{X}_i)$ leagă spațiul stărilor de spațiul măsurătorilor, și astfel definește *procesul de măsură* în același mod în care $P(\mathbf{X}_i | \mathbf{X}_{i-1})$ definește *procesul dinamic*. Procesul de măsură poate avea o parte predictibilă, o funcție care proiectează o instanță a stărilor într-o instanță a măsurătorilor, și o parte stohastică, ce descrie zgomotul din procesul de măsură.

Știind $P(\mathbf{Y}_i = y_i^r | y_0, \dots, y_{i-1})$, este posibil să decidem dacă o măsurătoare y_i^r aparține sau nu obiectului urmărit, sau cât de mult va influența această măsurătoare estimarea stării după cadrul i , în procesul de *actualizare a stării*.

1.4. Actualizarea stării (corecția)

În acest moment avem toți termenii disponibili pentru a calcula $P(\mathbf{X}_i | \mathbf{Y}_0 = y_0, \dots, \mathbf{Y}_i = y_i)$, scopul final al procesului de urmărire. Pentru actualizare, se folosește regula lui Bayes:

$$P(\mathbf{X}_i | y_0, \dots, y_i) = \frac{P(y_i | \mathbf{X}_i)P(\mathbf{X}_i | y_0, \dots, y_{i-1})}{\int P(y_i | \mathbf{X}_i)P(\mathbf{X}_i | y_0, \dots, y_{i-1})d\mathbf{X}_i} \quad (6)$$

Numitorul fracției poate fi văzut ca constant (probabilitatea unei măsurători luând în considerare toate stările posibile), și atunci se poate scrie:

$$P(\mathbf{X}_i | y_0, \dots, y_i) = K_i P(y_i | \mathbf{X}_i)P(\mathbf{X}_i | y_0, \dots, y_{i-1}) \quad (7)$$

De multe ori se ignoră complet această constantă, și relația de mai sus devine o relație de proporționalitate:

$$P(\mathbf{X}_i | y_0, \dots, y_i) \propto P(y_i | \mathbf{X}_i)P(\mathbf{X}_i | y_0, \dots, y_{i-1}) \quad (8)$$

În ecuația (8), predicția este densitatea de probabilitate anterioară (a priori), modelul de măsură este verosimilitatea unei măsurători față de probabilitatea anterioară a stării, iar rezultatul este densitatea de probabilitate estimată (a posteriori). O interpretare simplificată a procesului de actualizare a stărilor este că sistemul combină informația precisă cu informația măsurată pentru a obține cea mai bună estimare a stării entității urmărite pe baza informației disponibile până în acest moment.

1.5. Problemele care apar, și nevoie de aproximare

Ecuatiile urmăririi ca inferență probabilistică sunt prea complexe pentru a putea fi aplicate în cazul general. Mai mult, densitățile de probabilitate implicate sunt de multe ori imposibil de reprezentat analitic, și atunci ele trebuie approximate. Aproximarea se face sau prin forțarea densităților într-o formă definită cunoscută, precum funcția Gaussiană, sau prin menținerea unor reprezentări numerice pe întreaga durată a procesului. Fiecare tip de aproximare duce la o metodă practică de urmărire, care va fi descrisă în continuare.

2. Filtrul Kalman, inferența potrivită pentru densități Gaussiene

Cea mai populară reprezentare analitică a densității de probabilitate a stărilor și a celorlalte densități de probabilitate asociate procesului de urmărire (modelul dinamic, modelul de măsură) este forma funcția Gaussiană. Pentru o variabilă de stare multidimensională \mathbf{x} , valoarea funcției de densitate este:

$$p(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^n |\boldsymbol{\Sigma}|}} e^{-\frac{(\mathbf{x}-\boldsymbol{\mu})^T \boldsymbol{\Sigma}^{-1} (\mathbf{x}-\boldsymbol{\mu})}{2}} \quad (9)$$

Astfel, fiecare funcție de densitate de probabilitate este descrisă de doi parametri, valoarea medie $\boldsymbol{\mu}$ și matricea de covarianță $\boldsymbol{\Sigma}$. Densitatea de probabilitate maximă este în punctul de medie, și scade pe măsură ce variabila se îndepărtează, iar rata de scădere este controlată de matricea de covarianță. Scopul unui sistem de urmărire ce folosește distribuții Gaussiene este deci de a estima media și matricea de covarianță a variabilelor de stare, pe baza măsurătorilor.

$$\mathbf{X} \sim N(\boldsymbol{\mu}, \boldsymbol{\Sigma}) \quad (10)$$

Notăția de mai sus implică faptul că variabila aleatoare \mathbf{X} are o densitate de probabilitate normală (Gaussiană) cu media $\boldsymbol{\mu}$ și covarianța $\boldsymbol{\Sigma}$.

Dacă se utilizează modele Gaussiene de probabilitate, este foarte util ca modelul dinamic și modelul de măsură să fie exprimate ca transformări liniare, pentru ca natura Gaussiană să se păstreze.

$$\mathbf{X}_i \sim N(\mathbf{D}_i \mathbf{X}_{i-1}, \boldsymbol{\Sigma}_{D_i}) \quad (11)$$

$$\mathbf{Y}_i \sim N(\mathbf{M}_i \mathbf{X}_i, \boldsymbol{\Sigma}_{M_i}) \quad (12)$$

Dacă problema se poate formula în acest fel, cea mai bună soluție de urmărire este algoritmul filtrului Kalman [2]. Pașii acestui algoritm sunt următorii:

2.1. Predicția filtrului Kalman

Modelul dinamic liniar este aplicat mediei estimării anterioare, pentru a obține vectorul de stare prezis pentru cadrul curent.

$$\bar{\mathbf{X}}_i = \mathbf{D}_i \mathbf{X}_{i-1} \quad (13)$$

Matricea de covarianță a stării curente prezise este obținută prin aplicarea modelului dinamic la matricea de covarianță a celei mai recente estimări, și adăugarea unei matrice de covarianță ce reprezintă un model al zgomotului procesului dinamic, de medie zero (pentru a se putea ține cont de natura imprevizibilă a evoluției stării în timp).

$$\bar{\Sigma}_i = \Sigma_{D_i} + \mathbf{D}_i \Sigma_{i-1} \mathbf{D}_i^T \quad (14)$$

2.2. Asocierea datelor pentru filtrul Kalman

Filtrul Kalman este foarte sensibil la procesul de asociere a datelor [3], deoarece densitatea de probabilitate a tuturor fazelor filtrului este unimodală (are o singură medie, un singur vârf). Dacă există mai multe măsurători candidate pentru un obiect urmărit, verosimilitatea unei măsurători se va calcula pe baza stării curente prezise, și pe baza verosimilității se poate alege care date vor intra în procesul de corecție (actualizare).

Dacă modelul de măsură este liniar, densitatea de probabilitate a fiecărei măsurători candidate \mathbf{Y} se definește prin media $\bar{\mathbf{Y}}_i$ și matricea de covarianță $\Sigma_{\bar{\mathbf{Y}}_i}$.

$$\bar{\mathbf{Y}}_i = \mathbf{M}_i \bar{\mathbf{X}}_i \quad (15)$$

$$\Sigma_{\bar{\mathbf{Y}}_i} = \mathbf{M}_i \bar{\Sigma}_i \mathbf{M}_i^T + \Sigma_{M_i} \quad (16)$$

\mathbf{M}_i este transformarea liniară ce definește modelul de măsură (sau de observație), iar Σ_{M_i} definește imprevizibilitatea procesului de măsură, sau zgomotul (eroarea) măsurătorii. Densitatea de probabilitate a unui vector de măsură candidat este:

$$p(\mathbf{Y}) = \frac{1}{\sqrt{(2\pi)^n |\Sigma_{\bar{\mathbf{Y}}_i}|}} e^{-\frac{(\mathbf{Y} - \bar{\mathbf{Y}}_i)^T \Sigma_{\bar{\mathbf{Y}}_i}^{-1} (\mathbf{Y} - \bar{\mathbf{Y}}_i)}{2}} \quad (17)$$

Numărătorul fracției exponent se numește distanța Mahalanobis. Pentru a maximiza verosimilitatea, se vor căuta măsurătorile candidate care minimizează această distanță.

$$MD(\mathbf{Y}, \bar{\mathbf{Y}}_i, \Sigma_{\bar{\mathbf{Y}}_i}) = (\mathbf{Y} - \bar{\mathbf{Y}}_i)^T \Sigma_{\bar{\mathbf{Y}}_i}^{-1} (\mathbf{Y} - \bar{\mathbf{Y}}_i) \quad (18)$$

Selecția măsurătorilor pe baza verosimilității, sau pe baza distanței Mahalanobis, se poate face în mai multe moduri: selecția celei mai bune candidate, respingerea candidatelor de verosimilitate mică și combinarea celorlalte, etc.

2.3. Actualizarea stării prin filtrul Kalman

Având selectată măsurătoarea, pe care o vom nota în continuare cu \mathbf{Y}_i , sistemul poate actualiza starea (media și matricea de covarianță a vectorului de stare) folosind ecuațiile filtrului Kalman, și ciclul se poate repeta:

$$\mathbf{X}_i = \overline{\mathbf{X}}_i + \mathbf{K}_i (\mathbf{Y}_i - \mathbf{M}_i \overline{\mathbf{X}}_i) \quad (19)$$

$$\Sigma_i = (\mathbf{I} - \mathbf{K}_i \mathbf{M}_i) \overline{\Sigma}_i \quad (20)$$

$$\mathbf{K}_i = \overline{\Sigma}_i \mathbf{M}_i^T (\mathbf{M}_i \overline{\Sigma}_i \mathbf{M}_i^T + \Sigma_{M_i})^{-1} \quad (21)$$

Putem să ne închipuim procesul de urmărire a unei densități de probabilitate Gaussiană ca evoluția unui clopot Gaussian în timp. Procesul de predicție va muta centrul clopotului, iar calcularea matricei de covarianță a stării prezise va avea un efect de “lățire” a clopotului, crescând incertitudinea. Măsurătoarea asociată va muta vârful funcției Gaussiene, și va “strânge” clopotul în jurul noului maxim.

2.4. Problemele filtrului Kalman

Principala problemă a filtrului Kalman este reprezentarea Gaussiană a densității de probabilitate a stării. Această reprezentare face ca filtrul să fie incapabil să urmărească în mod direct mai multe ipoteze independente, care vor crea mai multe maxime în funcția de densitate de probabilitate.

Alte probleme rezultă din forma lineară a modelului de măsură și a modelului dinamic, care uneori nu sunt potrivite pentru lumea reală. Chiar dacă media stării poate fi obținută prin ecuații neliniare, calculul matricelor de covarianță necesită o transformare liniară. Aceste funcții sunt de obicei liniarizări locale ale funcțiilor de transformare (matrice Jacobiene), iar filtrul Kalman astfel modificat se numește Filtrul Kalman Extins (Extended Kalman Filter, EKF) [4].

3. Filtrarea bazată pe particule, soluția pentru problemele non-Gaussiene

O abordare practică pentru urmărirea unor funcții generice de densitate de probabilitate, numită CONDENSATION (CONDitional DENSity propaGATION), este descrisă în [5]. În loc să aproximeze o funcție de densitate de probabilitate în mod analitic, această soluție se bazează pe un număr N de valori discrete numite “eșantioane” sau “particule”. O analogie grafică este prezentată în figura 1. La fiecare moment de timp t , o particulă i este definită prin valoarea ei \mathbf{x}_t^i și o pondere π_t^i .

$$p(\mathbf{x}) \approx \{\mathbf{x}_t^i, \pi_t^i, i = 1 \dots N\} \quad (22)$$

Suma tuturor ponderilor este 1.

$$\sum_{i=1}^n \pi_i^t = 1 \quad (23)$$




Fig. 1. Analogie între o funcție de densitate de probabilitate și o mulțime de particule ponderate [10].

Problema urmăririi devine o problemă de evaluare a valorilor \mathbf{x}_t^i și a ponderilor π_t^i , dacă se dă un model dinamic și o funcție de densitate de probabilitate a procesului de observație (modelul de măsură).

Pentru optimizarea algoritmului, se adaugă pentru fiecare particulă un parametru suplimentar c_t^i , astfel încât reprezentarea unei particule devine $\{\mathbf{x}_t^i, \pi_t^i, c_t^i, i = 1 \dots N\}$. Acest parametru este definit ca suma ponderilor fiecărei particule, de la particula 1 până la particula i , fiind astfel o funcție de probabilitate cumulativă. Scopul acestui parametru va fi descris în secțiunea următoare.

$$c_t^i = \sum_{k=1}^i \pi_t^k \quad (24)$$

3.1. Algoritmul CONDENSATION – reeșantionarea

Fiecare iterație a algoritmului CONDENSATION are ca scop calcularea unei noi mulțimi de particule, $\{\mathbf{x}_t^i, \pi_t^i, c_t^i, i = 1 \dots N\}$, știind mulțimea de particule anterioare, $\{\mathbf{x}_{t-1}^i, \pi_{t-1}^i, c_{t-1}^i, i = 1 \dots N\}$, modelul dinamic și măsurătorile.

Primul pas al algoritmului se numește *reeșantionare*. O mulțime de particule (eșantioane) ponderate se transformă într-o nouă mulțime de eșantioane, de ponderi egale dar concentrare eterogenă în spațiul de valori al stării \mathbf{x} . Cele două mulțimi aproximează aceeași funcție de densitate de probabilitate.

Pentru a obține eșantioanele fără pondere, sistemul va face N extrageri aleatoare din funcția de densitate de probabilitate descrisă de ponderile eșantioanelor existente. Cu toate că generarea unui număr aleatoriu nu este o problemă complexă, ea este un pic mai dificilă dacă dorim să

extragem acest număr dintr-o densitate de probabilitate dată $p(x)$, după cum se arată în [6]. Dacă se dă funcția de densitate $p(x)$, funcția de distribuție de probabilitate $P(x)$ este definită ca:

$$P(x) = \int_{-\infty}^x p(v)dv \quad (25)$$

De asemenea, prin definiție vom avea:

$$\int_{-\infty}^{\infty} p(v)dv = 1 \quad (26)$$

$P(x)$ poate avea orice valoare din intervalul $[0, 1]$, astfel încât un număr aleatoriu r extras dintr-o distribuție uniformă r pe acest interval poate fi văzută ca o valoare aleatoare a lui $P(x)$. În mod formal putem spune că:

$$\int_{-\infty}^x p(v)dv = r \quad (27)$$

În ecuația de mai sus, x este necunoscută. Dacă vom rezolva ecuația și vom găsi pe x , vom obține un număr aleatoriu x din densitatea de probabilitate definită de $p(x)$.

Dacă densitatea de probabilitate este definită de ponderile particulelor, integrarea funcției de densitate de probabilitate înseamnă însumarea ponderilor particulelor:

$$\int_{-\infty}^x p(v)dv \Leftrightarrow \sum_{k=1}^i \pi_t^k = c_t^i \quad (28)$$

Din ecuația de mai sus reiese în mod clar rolul lui c_t^i . Acest termen este folosit pentru integrarea eficientă a funcției de densitate de probabilitate. Folosind acest termen, algoritmul de reșantionare este următorul:

For fiecare i de la 1 la N

- Generează un număr aleatoriu din densitatea de probabilitate uniformă, $r \in [0,1]$
- Găsește cel mai mic j pentru care $c_{t-1}^j \geq r$
- Setează $\bar{\mathbf{x}}_t^i = \mathbf{x}_{t-1}^j$

Ponderile noilor particule nu sunt importante, pentru că în acest moment fiecare particulă are aceeași importanță în fazele următoare ale algoritmului. Figura 2 ne arată analogia dintre o mulțime de particule ponderate și un set de particule fără pondere (de fapt ar putea fi considerate ca având fiecare o pondere egală cu $1/N$), pentru descrierea aceleiași funcții de densitate de probabilitate.




Fig. 2. Aproximarea aceleiași funcții de probabilitate, folosind particule cu pondere (sus) și particule fără pondere (jos) [10].

3.2. Algoritmul CONDENSATION - predicția

După aplicarea procesului de reeșantionare, particulele rezultate sunt folosite în procesul de *predicție*. În forma generală, predicția se realizează prin extragerea de valori din densitatea de probabilitate a modelului dinamic, $p(\mathbf{x}_t | \mathbf{x}_{t-1} = \bar{\mathbf{x}}_t)$. Această funcție descrie probabilitatea fiecărei stări posibile din prezent presupunând că starea anterioară este descrisă de valoarea particulei reeșantionate i . O abordare ceva mai pragmatică este să presupunem că fiecare stare nouă este derivată din starea anterioară printr-un proces determinist, descris de o funcție sau de o transformare liniară, combinat cu un proces aleatoriu. Dacă procesul determinist este liniar, se poate scrie pentru fiecare particulă i următoarea transformare:

$$\mathbf{x}_t^i = \mathbf{A}_t \bar{\mathbf{x}}_t^i + \mathbf{w}_t^i \quad (29)$$

Matricea \mathbf{A} codifică modelul dinamic liniar, posibil o ecuație de mișcare cu viteză uniformă, sau o mișcare uniform accelerată, iar w este o valoare aleatoare extrasă dintr-o distribuție potrivită pentru procesul aleatoriu, care se mai numește și zgomotul de proces, sau zgomotul de tranziție a stărilor. Dacă acest zgomot este Gaussian de medie zero, el este complet descris de matricea sa de covarianță.

Graficele din figurile următoare (figurile 3 și 4) descriu procesul de predicție, compus din aplicarea deterministă a modelului dinamic (numită deplasare deterministă, deterministic drift) și aplicarea zgomotului aleatoriu (proces numit difuzie stohastică, stochastic diffusion). Modelul dinamic produce deplasarea particulelor într-o manieră previzibilă, iar factorul aleatoriu le va împrăști în jurul valorilor deplasate.




Fig. 3. Deplasare deterministă a particulelor cu pondere egală [10].

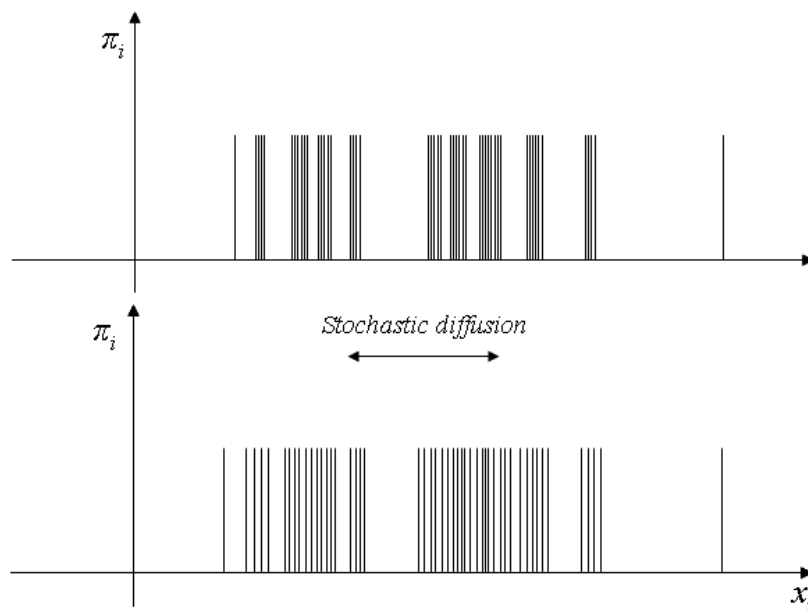


Fig. 4. Difuzia stohastică a particulelor cu pondere egală. În acest pas, păstrarea densității de probabilitate sub formă de particule ponderate ar crea probleme [10].

3.3. Algoritmul CONDENSATION - actualizarea

Ultimul pas al algoritmului este procesul de măsură/actualizare. În formularea generală a problemei urmăririi ca inferență probabilistică, actualizarea înseamnă aplicarea regulii lui Bayes pentru a obține densitatea de probabilitate posterioară pe baza densității anterioare și a modelului de măsură.

$$p(x_t | y_0, \dots, y_t) \propto p(y_t | x_t) p(x_t | y_0, \dots, y_{t-1}) \quad (30)$$

Densitatea de probabilitate anterioară este în acest moment complet codificată în distribuția particulelor cu pondere egală și valoare x_t^i în spațiul stărilor posibile. Densitatea de

probabilitate posterioară se obține prin ponderarea acestor particule pe baza informațiilor de măsură:

$$\pi_t^i = p(\mathbf{y}_t | \mathbf{x}_t = \mathbf{x}_t^i) \quad (31)$$

$p(\mathbf{y}_t | \mathbf{x}_t = \mathbf{x}_t^i)$ este verosimilitatea observației \mathbf{y}_t sub presupunerea că starea sistemului urmărit este descrisă de valoarea \mathbf{x}_t^i . Calcularea acestei verosimilități înseamnă de obicei proiectarea lui \mathbf{x}_t^i în domeniul măsurătorilor (folosind o transformare din spațiul stărilor în spațiul măsurătorilor) și efectuarea unei comparații între măsurătoarea prezisă și cea reală. Rezultatul comparației va fi o distanță, care se poate converti într-o valoare de probabilitate pe baza unei distribuții de probabilitate potrivite, precum o funcție Gaussiană cu covarianța/varianța potrivită. Observația totală \mathbf{y}_t poate fi compusă din M măsurători individuale, care uneori sunt numite și indicii [7], \mathbf{y}_t^i . Dacă presupunem că fiecare măsurătoare este independentă condițional de celelalte sub presupunerea că ele descriu starea \mathbf{x} , indiciile se pot combina prin înmulțire:

$$p(\mathbf{y}_t | \mathbf{x}_t = \mathbf{x}_t^i) = \prod_{j=1}^M p(\mathbf{y}_t^j | \mathbf{x}_t = \mathbf{x}_t^i) \quad (32)$$

În figura următoare se arată prin analogie cum devin particulele ponderate în faza de actualizare/măsurătoare. În acest moment, densitatea de probabilitate a stării este codificată în combinarea dintre distribuția particulelor și ponderea lor.




Fig. 5. Particulele primesc ponderea prin măsurătoare [10].

Deoarece o funcție de densitate de probabilitate trebuie să respecte condiția $\int_{\mathbf{x} \in \mathbb{R}^n} p(\mathbf{x}) d\mathbf{x} = 1$, n fiind dimensiunea vectorului de stare \mathbf{x} , ponderile particulelor trebuie normalizate astfel încât $\sum_{i=1}^n \pi_i^t = 1$. După acest pas, se recalculează ponderile cumulative c_i^t și sistemul este pregătit pentru un nou ciclu de urmărire.

3.4. Algoritmul CONDENSATION - estimarea

Majoritatea aplicațiilor care folosesc un algoritm de urmărire solicită ca la fiecare moment de timp t să se poată produce o estimare a stării, un vector \mathbf{x}_t cu valoarea stării estimate. Acest vector se poate obține prin însumarea vectorilor particulelor, înmulțiți cu ponderile lor:

$$\varepsilon(\mathbf{x}_t) = \sum_{i=1}^N \mathbf{x}_t^i \pi_t^i \quad (33)$$

Ecuția (33) nu este potrivită pentru orice situație, pentru că funcția de densitate de probabilitate estimată ar putea să fie multimodală, exprimând de fapt mai multe ipoteze sau ținte concurente. Dacă aceste ipoteze sunt doar zgomot, și sunt slab susținute de datele de măsură, sistemul poate să scape de ele punând un prag minimal pentru ponderile particulelor care intră în procesul de estimare, precum se propune în [8]. Dacă ne așteptăm ca sistemul să urmărească mai multe ipoteze, atunci particulele se pot grupa folosind criterii de vecinătate, și fiecare grup de particule va produce o estimare separată [9].

4. Bibliografie

- [1] D. Forsyth, J. Ponce, “Computer Vision – A Modern Approach”, Prentice Hall, 2003.
- [2] R.E. Kalman, “A New Approach to Linear Filtering and Prediction Problems”, Transactions of the ASME-Journal of Basic Engineering, vol. 82, 1960, pp. 35-45.
- [3] Y. Bar-Shalom, T.E. Fortmann, “Tracking and Data Association”, Academic Press Inc., 1988.
- [4] H. W. Sorenson, editor, “Kalman filtering: theory and application”, IEEE Press, 1985.
- [5] M. Isard, A. Blake, “CONDENSATION – conditional density propagation for visual tracking”, International Journal of Computer Vision, vol. 29, nr. 1, pp. 5-28, 1998.
- [6] R. K. Bock, “Sampling from a Probability Density Function”, 1998, resursă online la adresa: <http://rkb.home.cern.ch/rkb/AN16pp/node252.html>.
- [7] K. Macek, B. Williams, S. Kolski, R. Siegart, “A Lane Detection Vision Module for Driver Assistance”, IEEE/APS Conference on Mechatronics and Robotics, 2004.
- [8] U. Franke, H. Loose, C. Knoeppel, “Lane Recognition on Country Roads”, IEEE Intelligent Vehicles Symposium, 2007, pp. 99-104.
- [9] Y.M. Chan, S.S. Huang, L.C. Fu, P.Y. Hsiao, “Vehicle Detection under Various Lighting Conditions by Incorporating Particle Filter”, IEEE Intelligent Transportation Systems Conference, 2007, pp. 534-539.
- [10] R. Danescu, S. Nedevschi, “Probabilistic Lane Tracking in Difficult Road Scenarios Using Stereovision”, IEEE Transactions on Intelligent Transportation Systems, vol. 10, nr. 2, 2009, pp. 272-282.

II. Detecția și urmărirea benzilor de circulație folosind filtrele de particule

1. Introducere

Detecția drumului și a benzilor de circulație a fost și rămâne o preocupare importantă a cercetătorilor din domeniul sistemelor pentru asistența conducerii auto. O descriere precisă a acestor elemente, disponibilă chiar și în cele mai dificile scenarii, este esențială pentru ca autovehiculul autonom să poată parcurge un traseu în siguranță. Algoritmii dezvoltati au devenit tot mai complecși, pe măsură ce scenariile explorate au devenit tot mai dificile. De la tratarea scenariului de autostradă, sistemele de detecție și urmărire a benzilor de circulație au trecut la șoselele rurale, și apoi la cele urbane. Cu această tranziție, accentul inițial pe detectarea trăsăturilor delimitatoare, precum marcajele de pe șosea, a fost mutat spre modelare și estimare, folosind modele statice și dinamice cu constrângeri specifice, și proceduri de inferență probabilistică pentru a trata incertitudinile și erorile din procesul de măsură.

Algoritmii de detecție s-au transformat treptat în algoritmi de urmărire, de obicei pe bază de filtru Kalman. Folosirea acestui filtru are avantajul că poate reduce spațiul de căutare, eliminând trăsăturile prea îndepărtate de modelul prezis, și avantajul că poate produce un rezultat continuu, fără oscilații bruște.

Caracteristicile care fac din filtrul Kalman o soluție eficientă sunt exact caracteristicile care cauzează probleme în situațiile mai dificile. Viraje bruște, schimbări de bandă, geometrii atipice ale drumului, toate acestea pun probleme unui algoritm de urmărire care reprezintă densitatea de probabilitate sub forma unor funcții Gaussiene. Reducerea spațiului de căutare în jurul predicției unimodale face ca algoritmul să trateze cu dificultate ipotezele noi, și poate duce la acumularea erorilor dacă regiunile de căutare sunt atrase spre trăsături delimitatoare false.

Urmărirea benzilor de circulație pe baza filtrului Kalman a fost începută de Dickmanns [1], și de atunci au apărut mai multe soluții funcționale, precum cele descrise în [2] sau [3]. Algoritmii de urmărire a benzilor de circulație pe baza filtrului Kalman folosesc predicția bazată pe model pentru a defini regiuni de căutare pentru extragerea noilor delimitatori, și folosesc apoi delimitatorii extrași pentru a actualiza starea. Această abordare presupune că drumul se modifică într-o manieră continuă, fără salturi, iar eventualele discontinuități/tranziții sunt abordate prin re-inițializarea procesului de urmărire. Soluția prezentată în [4] tratează unele cazuri particulare de discontinuități ale drumului prin folosirea simultană a două instanțe ale modelului drumului, dar soluții de genul acesta ne arată că filtrul Kalman nu este, în mod natural, potrivit pentru urmărirea discontinuităților.

Având în vedere deficiențele filtrului Kalman, mai mulți cercetători au propus soluții pe baza filtrului de particule. O soluție de urmărire a benzilor pe baza filtrului de particule începe de obicei cu reeșantionarea particulelor, urmată de deplasare și difuzie, apoi de măsurătoare. Procesul de măsură este de obicei mult mai simplu decât în cazul filtrului Kalman, deoarece constă într-o comparație dintre ipoteza particulei și datele de măsură, iar în urma comparației se calculează o pondere. Astfel, nu sunt necesari algoritmi complecși pentru extragere de trăsături elaborate. Pe de altă parte, deoarece procesul de comparație se aplică pentru fiecare particulă în parte, simplitatea măsurătorii este esențială pentru a avea o execuție rapidă a algoritmului.

În [5] este descris un algoritm de urmărire a benzilor de circulație bazat pe metoda Condensation [6], ce folosește punctele detectate ca elemente de marcaj ca trăsături de măsură. Fiecare punct din imagine primește un scor pe baza distanței la cel mai apropiat punct de marcaj, iar aceste scoruri sunt folosite pentru a calcula ponderea fiecărei particule. Algoritmul propus folosește eșantionarea partiționată (eșantionare în doi pași pe submulțimi ale spațiului de stare, obținând un efect multirezoluție), eșantionarea bazată pe importanță (pe pondere), și eșantioane de inițializare, care sunt extrase în mod complet aleatoriu din întreg domeniul permis pentru spațiul de stare, pentru a putea reacționa mai rapid la schimbări.

În [7] se descrie un sistem de urmărire a benzilor ce folosește cadrul filtrului de particule pentru a integra mai multe indicii precum culoarea, muchiile, răspunsul la filtrul LoG (Laplace of Gaussian). Pentru fiecare indice se face o comparație între datele din imagine și particule, se calculează o verosimilitate, iar aceste verosimilități se combină ulterior prin înmulțire. Și această soluție folosește eșantioane de inițializare, și eșantionare suplimentară în jurul particulelor cu ponderea cea mai mare pentru a crește acuratețea estimării.

Modul mult simplificat în care filtrul de particule tratează informațiile de măsură permite utilizarea unei largi varietăți de indicii. În lucrarea [8] se descrie un algoritm de urmărire a benzilor pentru drumuri rurale, unde spațiul imagine se împarte în zone de drum și zone non-drum, iar fiecare din aceste zone contribuie la ponderea finală prin intensitate, culoare, informații despre muchii și despre textură. Verosimilitatea fiecărei trăsături de a aparține unor zone drum sau non-drum se calculează folosind histograme antrenate pe exemple, permițând astfel o densitate de probabilitate multimodală nu doar pentru starea benzilor, ci și pentru măsurători. În [9] se prezintă avantajele folosirii filtrului de particule pentru fuzionarea indicilor de natură diferită, când trăsăturile extrase din imagine sunt combinate cu informație GPS și informație din hartă, pentru estimarea benzilor pe distanță mare. Autorii articolului [10] descriu o abordare hibridă, ce combină ipotezele marginilor benzilor de circulație generate printr-un algoritm de tip RANSAC cu ipotezele dintr-un filtru de particule, folosind ulterior un mecanism probabilistic pentru a alege cele mai bune margini pentru descrierea benzilor.

În acest capitol se va descrie un sistem de detecție și urmărire a benzilor de circulație care combină avantajele filtrului de particule cu stereoviziunea și procesarea imaginilor de intensitate, pentru a realiza o estimare robustă în scenariile dificile din mediul urban, din mediul rural, și de pe autostradă. Metoda descrisă este o contribuție originală a autorului, publicată inițial în articolul de jurnal [13]. Unele figuri din acest capitol sunt preluate din publicația originală.

2. Soluția pe scurt

Sistemul propus va evalua în mod continuu starea benzii de circulație prin intermediul unei mulțimi de particule. Nu există o fază de inițializare, astfel că fiecare ciclu este executat în același fel, după cum se arată în figura 1.

Ciclul de urmărire pornește cu procesul de re-eșantionare a particulelor, care se realizează parțial prin utilizarea particulelor ponderate în ciclul anterior, și parțial din distribuția generică de probabilitate care acoperă întreg spațiul stărilor, pentru a permite sistemului să trateze posibilele schimbări discontinue. Deplasarea deterministă este aplicată întregii mulțimi de particule reeșantionate, și se bazează pe parametrii de mișcare ai vehiculului propriu, precum viteza de deplasare, viteza de rotație (viteza angulară), și pe timpii de achiziție a cadrelor

procesate, care sunt marcați cu precizie de milisecundă. Difuzia stohastică va afecta fiecare particulă din setul reeșantionat.

Detecția unghiului de aplecare (*pitch*) se va realiza separat de mecanismul de urmărire bazat pe particule folosind tot o abordare probabilistică, dar fără a ține cont de istoria acestui unghi, deoarece el se poate schimba în mod imprezvizibil din cauza imperfecțiunilor suprafeței drumului. Acest unghi este folosit pentru a selecta trăsăturile de drum, care sunt apoi folosite pentru a pondera particulele.

După ponderarea particulelor, acestea sunt supuse unui proces de validare, care va verifica dacă ele sunt concentrate în mod corect pe o bandă de circulație. Dacă validarea este cu succes se va genera o stare estimată a acestei benzi.

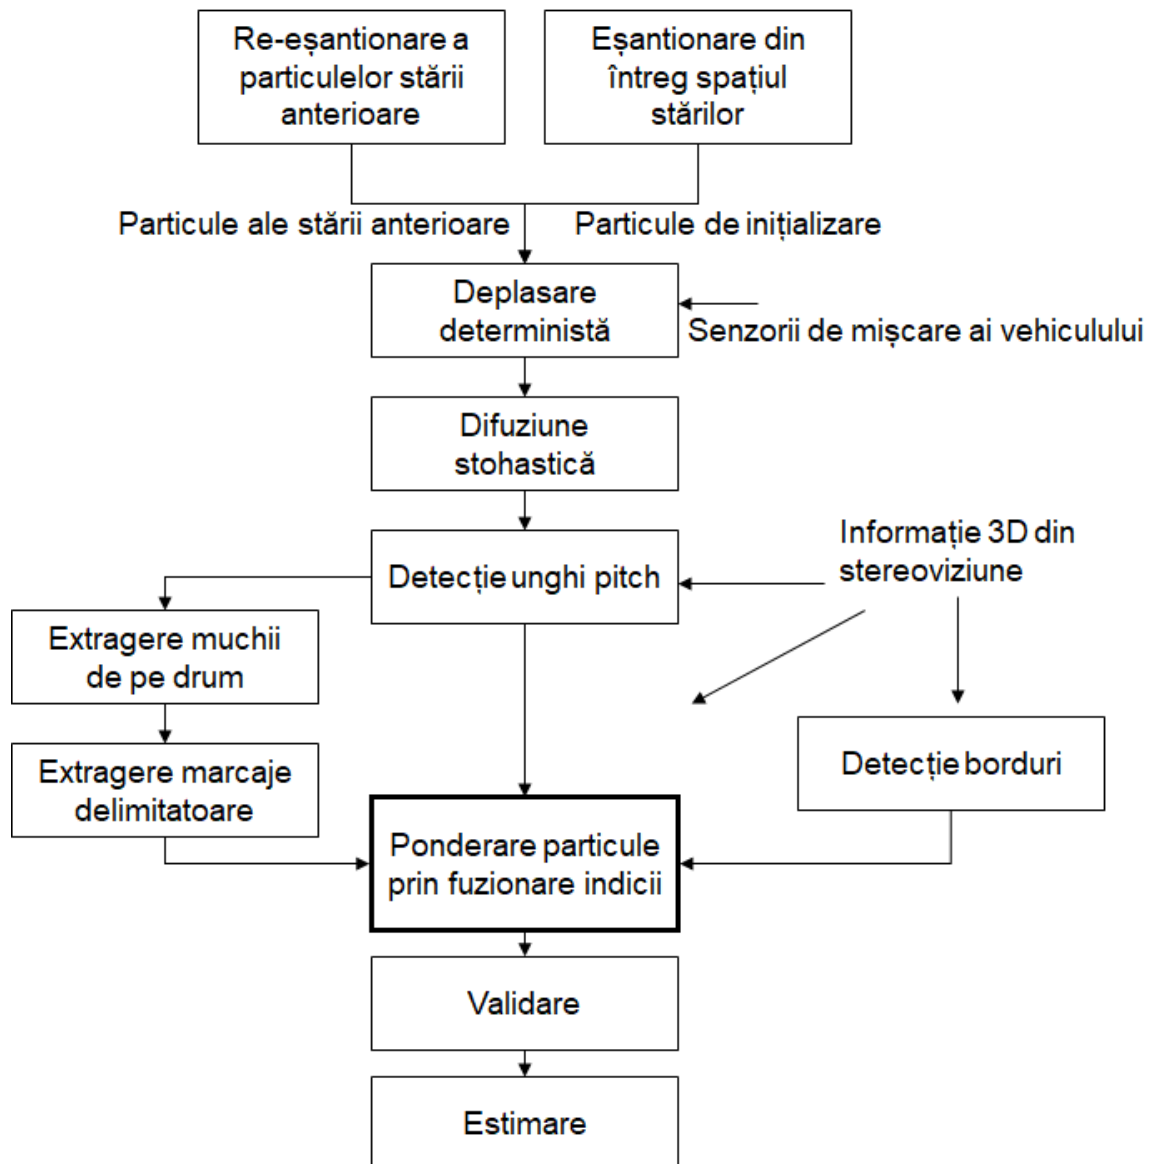


Fig. 1. Vedere de ansamblu a algoritmului de urmărire

3. Descrierea algoritmului de urmărire

3.1. Particulele benzilor de circulație

Densitatea de probabilitate a stării benzii de circulație este descrisă la un anumit timp t de o mulțime de particule ponderate N : $p(\mathbf{x}) \approx \{\mathbf{x}_t^i, \pi_t^i, i=1\dots N\}$. Valoarea particulei, \mathbf{x} , este o ipoteză asupra stării benzii de circulație, sub forma unui vector de parametri.

Sistemul de coordonate utilizat are originea pe șosea, în cel mai avansat punct acoperit de vehiculul nostru, centrat față de lățimea vehiculului. Axa Z este de-a lungul axei de deplasare înainte a vehiculului, axa X este coordonata laterală pozitivă spre dreapta, iar axa Y este axa verticală, pozitivă spre centrul Pământului. Banda de circulație este o suprafață 3D care se întinde în fața autovehiculului, și este delimitată de două curbe. Coordonata X a curbelor delimitatoare depinde de parametrii benzii, de distanța Z și de tipul delimitatorului, T (stânga sau dreapta).

$$X = h(Z, T) \quad (1)$$

Vom numi ecuația de mai sus profilul orizontal al benzii. Parametrii care afectează rezultatul funcției h vor fi considerați parametrii profilului orizontal. Ei sunt curbura orizontală, unghiul de orientare (*yaw*), deplasamentul lateral și lățimea benzii.

În același fel putem descrie și variația coordonatei Y a fiecărei curbe delimitatoare, cu ecuația profilului vertical al drumului:

$$Y = v(Z, T) \quad (2)$$

Sistemul de urmărire a fost proiectat într-o manieră modulară, ecuațiile pentru profilul vertical și orizontal fiind ușor reconfigurabile. Funcția de măsură este independentă de modelul 3D, atâta timp cât acest model poate genera puncte 3D pentru delimitatori. Din experimentele noastre, am decis că următorii parametri descriu în mod suficient banda de circulație:

$$\mathbf{x}_t^i = \begin{bmatrix} W - \text{latime banda} \\ C_H - \text{curbura orizontala} \\ C_V - \text{curburaverticala} \\ X_C - \text{deplasament lateral} \\ \alpha - \text{unghiaplecare} \\ \gamma - \text{unghiinclinare} \\ \psi - \text{unghiorientare} \end{bmatrix} \quad (3)$$

Datorită naturii configurabile a sistemului, am putut experimenta cu mai multe modele și mulțimi de parametri. Un model care a inclus și un parametru pentru variația lățimii a fost testat în condiții de autostradă, dar modelul mai simplu descris de ecuația (3) s-a dovedit mai robust în scenariile urbane. Un argument convingător împotriva utilizării unui model de reprezentare

prea complex este că distanța de vizibilitate este oricum limitată datorită proprietăților camerei și a caracteristicilor traficului urban.

3.2. Predicția

Înainte de a aplica modelul de evoluție a stării, starea estimată la pasul anterior, descrisă de particulele ponderate, trebuie reeșantionată în particule de pondere egală. O fracțiune $R=0.1 N$ a particulelor se va extrage dintr-o distribuție uniformă ce acoperă tot domeniul permis al parametrilor benzii de circulație. Aceste particule reprezintă probabilitatea că banda urmărită la momentul curent să fie eronată, sau probabilitatea de apariție a unei benzi candidate mai bune, de exemplu în cazul unei schimbări de bandă sau în cazul despărțirii drumului în două benzi.

După reeșantionare, fiecare particulă este transformată prin predicție, folosind ecuația modelului dinamic al benzii de circulație:

$$\bar{\mathbf{x}}_t^i = \mathbf{A}_t \hat{\mathbf{x}}_{t-1}^i + \mathbf{B}_t \mathbf{u}_t + \mathbf{w}_t \quad (4)$$

$$\mathbf{A}_t = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & -\frac{s_t^2}{2} & 0 & 1 & 0 & 0 & s_t \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & -s_t & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (5)$$

$$\mathbf{B}_t = \begin{bmatrix} 0 \\ 0 \\ 0 \\ \frac{s_t^2}{2} \\ 0 \\ 0 \\ s_t \end{bmatrix} \quad (6)$$

$$\mathbf{u}_t = c_t \quad (7)$$

Matricea \mathbf{A}_t reprezintă transformarea liniară care exprimă modul în care parametrii benzii de circulație evoluează în timp în absența unei intervenții din partea șoferului, iar matricea \mathbf{B}_t este matricea care face legătura dintre variabilele de intrare și evoluția benzii în timp. Intrarea sistemului este formată din variabila c_t , curbura traiectoriei vehiculului propriu, decisă de șofer, care în cazul nostru particular este derivată din viteza angulară, direct măsurată de senzorii inerțiali cu care este echipat autovehiculul, și citită prin intermediul magistralei CAN. Matricele \mathbf{A}_t și \mathbf{B}_t depind de distanța parcursă între două măsurători, s_t , calculată prin

înmulțirea vitezei citite de pe magistrala CAN cu timpul dintre două cadre capturate de camera video.

Partea deterministă a predicției este exprimată prin $\mathbf{A}_t \hat{\mathbf{x}}_{t-1}^i + \mathbf{B}_t \mathbf{u}_t$, unde se aplică legile de mișcare. Prin această ecuație, fiecare posibilă configurație anterioară a drumului este proiectată în prezent. În afară de mișcarea deterministă, fiecare particulă este afectată de o valoare aleatoare \mathbf{w}_t , extrasă dintr-o distribuție Gaussiană de medie zero și matrice de covarianță \mathbf{Q}_t . Această matrice de covarianță exprimă incertitudinea modelului de mișcare între două măsurători, și astfel ea trebuie scalată cu timpul scurs între aceste măsurători, incertitudinea crescând cu timpul. Se definește o matrice de covarianță \mathbf{Q}_0 , calibrată pentru un interval de timp de 100 ms, iar matricea efectivă \mathbf{Q}_t se obține prin scalarea lui \mathbf{Q}_0 cu raportul dintre intervalul de timp dintre cadre și intervalul etalon de 100 ms.

După aplicarea predicției, populația de particule codifică presupunerile la momentul actual asupra stării benzii de circulație, derivate din starea anterioară și legile de mișcare, precum și incertitudinile asupra acestor presupuneri. Populația de particule este în acest moment pregătită pentru măsurătoare.

3.3. Detecția unghiului de aplecare

Unghiul de aplecare este tratat în mod diferit, în afara mecanismului de urmărire bazat pe particule, din două motive: acest unghi nu este foarte previzibil, el putând varia brusc din cauza unor manevre de accelerație sau frână sau dacă se întâlnesc imperfecțiuni pe suprafața drumului, și acest unghi va decide în continuare care sunt datele de măsură utilizabile pentru estimarea benzii de circulație, el fiind un element esențial în selecția punctelor 3D care aparțin drumului.




Fig. 2. O scenă complexă cu drum, vehicule și ziduri, și o vedere laterală a punctelor 3D reconstruite prin stereoviziune [13]. Este pus în evidență domeniul în care vom căuta unghiul de aplecare.

Considerând originea sistemului de coordonate pe șosea, imediat în fața autovehiculului, presupunem că pentru aproximativ 10-20 de metri drumul, așa cum este el văzut din lateral, va fi o dreaptă care trece prin această origine. În sistemul de coordonate dat, această dreaptă va depinde deci doar de unghiul de aplecare (pitch). Detecția unghiului de aplecare înseamnă de fapt găsirea celei mai bune drepte pe baza punctelor 3D date.

Procesul de detecție a unghiului de aplecare începe prin construirea unei histograme polare, care numără punctele 3D de-a lungul unor drepte candidate care trec prin origine, în planul lateral distanță-înălțime. Aceste drepte corespund unor valori discrete candidate pentru unghiul de aplecare, la intervale de 0.1 grade, cu domeniul de variație între -2 și 2 grade. Algoritmul pentru construirea histogramei este următorul:

Inițializează histograma polară $H(index)$ cu 0, pentru fiecare $index$

For fiecare punct 3D p

Dacă $distanța(p) > Limita$ treci la următorul punct, altfel:

Găsește unghiul dreptei care trece prin p și origine

$$\alpha_p = \tan^{-1} \frac{înălțime(p)}{distanța(p)} \quad (8)$$

Dacă $\alpha_p > 2^\circ$ or $\alpha_p < -2^\circ$ treci la următorul punct, altfel:

Găsește indexul lui α_p în histograma polară:

$$index_p = \frac{\alpha_p + 2^\circ}{0.1^\circ}$$

Incrementează histograma polară cu o cantitate variabilă ce ia în considerare densitatea variabilă a punctelor cu distanța:

$$H(index_p) = H(index_p) + \frac{distanța(p)^2}{K} \quad (9)$$

End For

Pentru găsierea unghiului optim, vom folosi o abordare probabilistică, ceea ce înseamnă că pentru fiecare unghi candidat α_{index} vom calcula densitatea de probabilitate $p(\alpha = \alpha_{index})$, adică probabilitatea ca unghiul candidat să fie unghiul real, pe baza informației de măsură disponibilă.

În procesul de calculare a $p(\alpha = \alpha_{index})$ vom face câteva presupuneri. Prima presupunere este că istoria unghiului nu contează, deoarece variațiile sunt datorate în mare parte imperfecțiunilor suprafeței drumului, care nu sunt ușor de prezis. Această presupunere ne permite să considerăm că densitatea de probabilitate a acestui unghi va fi decisă doar pe baza măsurătorilor curente:

$$p(\alpha | y_1, y_2, \dots, y_t) = p(\alpha | y_t) \quad (10)$$

A doua presupunere este că nu avem o densitate de probabilitate a priori predefinită, care s-ar putea traduce prin anumite valori preferate ale unghiului, și în consecință densitatea de probabilitate a stării unghiului este direct proporțională cu verosimilitatea măsurătorilor.

$$p(\alpha | y_t) \propto p(y_t | \alpha) \quad (11)$$

Verosimilitatea măsurătorilor se calculează prin intermediul a două indicii, care derivă din următoarele condiții pe care le impunem punctelor 3D proiectate în planul lateral:

- Punctele care aparțin drumului se vor proiecta sub forma unei drepte, deci vor fi colineare în planul înălțime-distanță
- Majoritatea punctelor 3D din scenă se vor găsi deasupra suprafeței drumului.

Pe baza primei condiții putem decide că verosimilitatea măsurătorilor este direct proporțională cu valoarea histogramei polare H , iar pe baza celei de-a doua condiții verosimilitatea măsurătorilor este proporțională cu histograma cumulativă derivată din H , CH .

$$p(y_H | \alpha = \alpha_{index}) \propto H(index) \quad (9)$$

$$p(y_{CH} | \alpha = \alpha_{index}) \propto CH(index) \quad (10)$$

Cele două verosimilități sunt combinate prin înmulțire, pentru a calcula densitatea finală pentru unghiul de aplecare:

$$p(\alpha = \alpha_{index} | y_t) \propto H(index)CH(index) \quad (11)$$

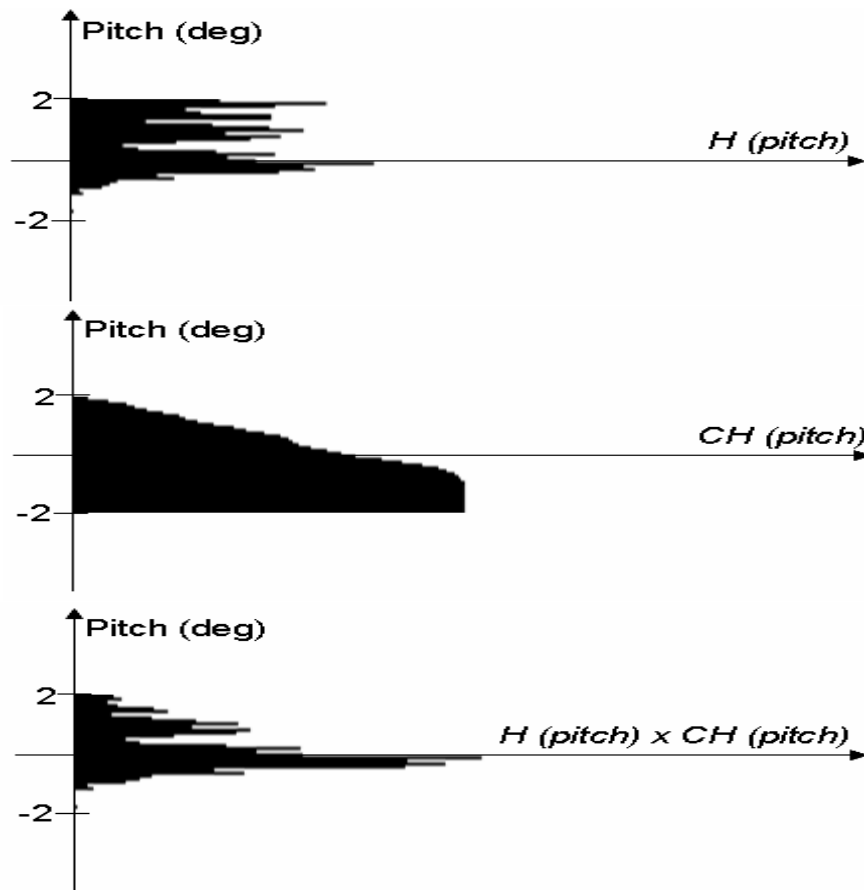


Fig. 3. Combinarea indiciilor pentru unghiul de aplecare: sus, histograma polară; mijloc, histograma cumulativă; jos, combinarea celor două [13].

Unghiul candidat cu cea mai mare verosimilitate este ales ca unghiul estimat de aplecare. În figura 3 este descris grafic acest proces, care duce la un maxim clar chiar dacă scena complexă cauzează mai multe vârfuri în histograma polară.

Unghiul estimat este introdus în vectorii de stare ai particulelor prezise. De asemenea, pe baza acestui unghi sunt selectate punctele 3D corespunzătoare suprafeței drumului, pentru a putea fi utilizate în fazele ulterioare ale procesului de măsură.

3.4. Proiecția particulelor în spațiul de măsură

Detecția unghiului de aplecare este singurul pas al procesului de măsură care utilizează spațiul 3D. Ceilalți pași implică compararea particulelor cu datele de măsură din spațiul imagine. Pentru a obține această comparație, din fiecare stare de forma $\bar{x}_t^i = (W, C_H, C_V, X_C, \alpha, \gamma, \psi)^T$ a unei particule se va genera un vector în spațiul măsurătorilor, de forma $\bar{y}_t^i = (v_1, \dots, v_P, u_{L,1}, \dots, u_{L,P}, u_{R,1}, \dots, u_{R,P})$, unde P este numărul de perechi de puncte stânga-dreapta care vor descrie banda. Valorile v sunt coordonatele rândurilor din imagine, iar valorile u sunt coordonate ale coloanelor. Coordonatele rând sunt comune pentru delimitatorii stâng și drept.

Pentru a obține \bar{y}_t^i din \bar{x}_t^i , vom parcurge următorii pași:

- Se generează, pentru fiecare delimitator de bandă (stâng și drept) P puncte în spațiul 3D. Punctele sunt egal depărtate pe axa distanță Z , și coordonatele X și Y (lateral și vertical) sunt generate de profilul orizontal și vertical al benzii. Cel mai apropiat punct va avea distanța Z_B , o constantă reglată în așa fel încât acest punct să fie vizibil în imagine, dar aproape de marginea de jos a acesteia. Întreaga mulțime de puncte va fi desfășurată pe o distanță D , care va fi automat ajustată cu viteza autovehiculului. La o viteză mai mare, distanța D va fi crescută, pentru a acoperi o distanță mai mare de drum, iar la o viteză mică D va fi scăzută pentru a ajuta sistemul să trateze curbele strânse sau zonele de drum cu multe obstacole. Distanța D acoperă o secundă de mișcare la viteza curentă a autovehiculului, dar nu poate fi mai scurtă de 5 m și nici mai lungă de 60 m.
- Se proiectează punctele 3D obținute la pasul anterior în spațiul imagine, folosind parametrii calibrați ai camerei. Pentru fiecare delimitator, se va obține un lanț de puncte 2D, cu distanță variabilă între ele.
- Se intersectează segmentele obținute din punctele proiectate consecutive cu drepte orizontale egal depărtate una de alta. Punctele de intersecție sunt punctele care formează reprezentarea particulei în spațiul imagine, \bar{y}_t^i .

Procesul este ilustrat vizual în figurile 4 și 5.




Fig. 4. Pentru fiecare delimitator de bandă (stânga sau dreapta) se generează puncte 3D egal depărtate folosind parametrii fiecărei particule. Aceste puncte sunt apoi proiectate în spațiul imagine [13].




Fig. 5. Linii orizontale egal depărtate se intersectează cu segmentele formate de punctele delimitator proiectate. Punctele intersecție rezultate sunt reprezentarea particulei în spațiul de măsură [13].

Rezultatul proiecției unei mulțimi complete de particule în spațiul imagine este prezentat în figura 6.



Fig. 6. Particulele în spațiul imagine [13]. Stânga – particule complet aleatoare, la pornirea sistemului; dreapta – particule precise în modul de urmărire normal, unele fiind complet aleatoare, dar cele mai multe fiind apropiate de banda reală.

3.5. Indiciile vizuale

După detecția unghiului de aplecare, acesta poate fi folosit pentru o aproximare a geometriei drumului, pentru a facilita selecția punctelor 3D care aparțin acestuia. Punctele de muchie din imagine care corespund punctelor 3D de pe drum sunt folosite ca un prim indiciu pentru măsură.

Dintre punctele de muchie ale drumului sunt selectate punctele de marcaj, pe baza algoritmului clasic de detecție a tranzițiilor de tip întunecat-luminos-întunecat [11]. În afară de punctele de marcaj, alte trăsături de mare importanță sunt bordurile, care sunt detectate pe baza variațiilor înălțimilor punctelor extrase prin stereoviziunea densă [12]. Bordurile detectate în spațiul 3D sunt convertite în muchii în spațiul imagine. Bordurile și marcajele sunt considerate a fi de prioritate egală, și sunt astfel introduse într-o hartă de muchii speciale, al doilea indiciu vizual.

Pentru a permite comparația dintre particule și măsurătoare, fiecare hartă de indicii (muchii de drum și muchii speciale delimitatoare) sunt supuse transformării distanță (Distance Transform).

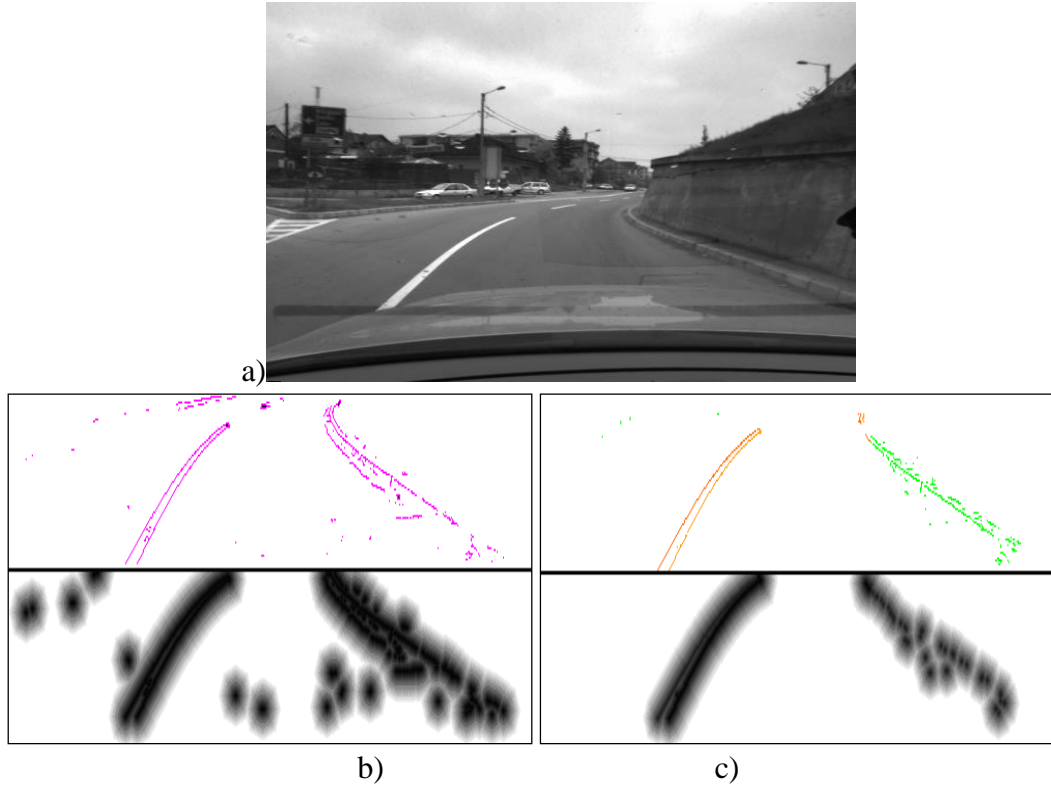


Fig. 7. Informația vizuală: a) imaginea originală, b) muchii corespunzătoare punctelor 3D de pe suprafața drumului, și transformarea distanță a acestora, c) marcaje și borduri, cu imaginea distanță asociată[13].

3.6. Ponderarea particulelor prin măsurătoare

Având densitatea de probabilitate a priori, codificată în distribuția valorilor particulelor prin spațiul stărilor, putem calcula densitatea de probabilitate posterioară, care va codifica informația pe care o avem despre starea sistemului până la momentul prezent t . Acest ultim pas se realizează prin asignarea de ponderi pentru fiecare particulă, folosind verosimilitatea măsurătorilor față de fiecare ipoteză a stării.

$$\pi_t^i = p(\mathbf{y}_t | \mathbf{x}_t = \mathbf{x}_t^i) \quad (12)$$

Verosimilitatea măsurătorii se obține prin înmulțirea verosimilității muchiilor cu verosimilitatea marcajelor și bordurilor, presupunând independența condițională a acestora.

$$p(\mathbf{y}_t | \mathbf{x}_t = \mathbf{x}_t^i) = p(\text{road_edges} | \mathbf{x}_t = \mathbf{x}_t^i) \cdot p(\text{mark_curb} | \mathbf{x}_t = \mathbf{x}_t^i) \quad (13)$$

Pentru a calcula verosimilitatea celor două indicii, se va calcula o distanță dintre ipoteza stării și măsurătoare. În acest sens se folosește imaginea transformată distanță.

În cazul ideal, proiecția granițelor benzilor de circulație ar trebui să se potrivească exact pe muchiile ce constituie indiciile vizuale. De asemenea, zona din interiorul benzii ar trebui să fie lipsită de muchii pe cât posibil. Pentru a putea testa aceste două condiții, se definesc două tipuri de puncte: punctele pozitive, care sunt cele de pe delimitatorii benzilor de circulație proiectate

în imagine, și puncte negative, care sunt puncte apropiate de margini, dar aflate în interiorul zonei de bandă. Cele două tipuri de puncte sunt arătate în figura 8.




Fig. 8. Puncte pozitive și puncte negative. Punctele pozitive (roșu) sunt pe delimitatori, iar cele negative (galben) sunt în interiorul benzii [13].

Punctele pozitive vor genera distanța pozitivă. Aceasta se obține prin medierea valorilor pixelilor din transformata distanță de la coordonatele punctelor pozitive. Distanța corespunzătoare punctelor negative este complementul valorii medii a pixelilor din imaginea transformată distanță de la coordonatele acestor puncte. Cele două distanțe se combină prin medie ponderată (ecuația 14). Valorile ponderilor α și β au fost stabilite ca 2 și 1, prin experiment. În această ecuație, M notează tipul măsurătorii (E – muchie simplă corespunzătoare punctelor drumului, S – muchie specială, marcaj sau bordură).

$$D^M = \frac{\alpha D^M(+)+\beta D^M(-)}{(\alpha+\beta)} \quad (14)$$

Pentru fiecare măsurătoare M se va calcula verosimilitatea folosind o distribuție Gaussiană pentru a transforma distanța într-o valoare de probabilitate.

$$p(M|\mathbf{x}_t=\mathbf{x}_t^i)=\frac{1}{\sigma_M\sqrt{2\pi}}e^{-\frac{D_M^2}{2\sigma_M^2}} \quad (15)$$

Fiecare particulă va primi ca pondere produsul celor două verosimilități. Tot în acest pas, particulele care prezintă o ipoteză degenerată asupra benzii de circulație, precum o bandă de lățime prea mică pe care nu ar încăpea o mașină, sau o bandă prea lată, sau prea deplasată față de poziția noastră, vor primi o pondere nulă, pentru ca în următorul ciclu de urmărire ele să fie eliminate de procesul de reeșantionare.

Ultimul pas al algoritmului de urmărire folosind particulele este de a normaliza ponderile, astfel încât ele să dea, prin însumare, valoarea 1. În acest moment sistemul este pregătit pentru următorul ciclu.

3.7. Validarea rezultatului

Spre deosebire de algoritmi de urmărire bazați pe filtrul Kalman, filtrele de particule nu au nevoie de inițializare sau de validarea măsurătorilor înainte de actualizarea stării. Particulele vor evolua liber, și se vor grupa în final în jurul estimării optime, atâta timp cât sistemul este

bine proiectat și măsurătorile sunt relevante. Totuși, utilizarea unui sistem de acest gen în practică impune ca sistemul să decidă dacă avem un rezultat valid sau nu.

O posibilă variantă de validare este analizarea distribuției particulelor în spațiul stării, și generarea unei decizii pozitive în cazul în care acestea sunt grupate rezonabil de strâns în jurul unei ipoteze. Din păcate, am observat că particulele tind să se grupeze destul de bine chiar și dacă măsurătorile sunt foarte slabe, și acest lucru nu garantează că estimarea finală este corectă.

O soluție care dă rezultate mai bune este să comparăm ponderea medie a particulelor prezise cu ponderea medie a particulelor complet aleatoare (particulele de inițializare). Dacă N este numărul total de particule, iar R este numărul de particule complet aleatoare, care în implementarea noastră sunt inserate la începutul listei de particule, se definește factorul de calitate q astfel:

$$q = \frac{R \sum_{i=R+1}^N \pi_t^i}{(N-R) \sum_{i=1}^R \pi_t^i} \quad (16)$$

Dacă q este mai mare decât un prag, banda este considerată validă pentru a fi afișată, și se va estima un vector mediu pe baza particulelor individuale și a ponderilor lor. Un factor de calitate mare înseamnă că datele de măsură susțin banda prezisă mai mult decât ar susține o bandă prezisă complet aleator. Pragul peste care considerăm banda a fi validă este stabilit, prin experimente, la 10.

Vectorul de stare estimat pentru banda urmărită este:

$$\varepsilon(\mathbf{x}_t) = \frac{\sum_{i=1}^N \mathbf{x}_t^i \pi_t^i \delta_t^i}{\sum_{i=1}^N \pi_t^i \delta_t^i} \quad (17)$$

Nu toate particulele sunt luate în considerare pentru estimarea finală, iar acest lucru ne este indicat de condiția δ_t^i . Condiția este ca particula să aibă o pondere mai mare sau egală cu media ponderilor particulelor din mulțime.

$$\delta_t^i = \begin{cases} 0, & \text{dacă } \pi_t^i < \frac{1}{N} \\ 1, & \text{altfel} \end{cases} \quad (18)$$




Fig. 9. Banda de circulație estimate pe baza particulelor și a ponderilor [13].

4. Teste și rezultate

Notă: Fișierele video care prezintă rezultatele pot fi descărcate de la adresa http://users.utcluj.ro/~rdanescu/lane/lane_eval.htm.

4.1. Comparație cu filtrul Kalman

Sistemul de urmărire a benzilor de circulație bazat pe filtrul de particule și stereoviziune a fost proiectat pentru a aborda situațiile dificile, unde filtrul Kalman are mari probleme. Aceste scenarii pot fi variate, dar toate se pot defini prin termenul “drum cu discontinuități”, sau “drum care prezintă singularități”. Cele mai comune situații care se pot considera discontinuități sunt: apariția și dispariția marcajelor de bandă, manevre de schimbare a benzii, despărțire sau fuzionare a benzilor, schimbare bruscă a direcției benzii, schimbare bruscă a curbării, sau nefuncționare temporară a senzorului cauzată de condiții interne sau externe.

O soluție bazată pe filtrul Kalman are probleme cu discontinuitățile datorită următoarelor caracteristici:

- Doar o configurație de drum este urmărită la un moment dat
- Starea curentă este folosită pentru a prezice zonele de căutare pentru detecțiile următoare, iar acest lucru exclude măsurătorile din zonele discontinue
- Este nevoie de timp pentru a se renunța la o ipoteză urmărită, și pentru inițializarea unei urmăriri noi
- Inițializarea unei urmăriri noi implică aplicarea algoritmilor complecși de măsură pe întreg spațiul imaginii, eliminând avantajul spațiului redus de căutare.

Am testat algoritmul bazat pe filtrul de particule în scenarii cu problemele specificate mai sus, și am obținut următorul comportament:

1. În cazul apariției și dispariției marcajelor: datorită faptului că nu avem o detecție în sensul clasic, nu a fost nevoie de timp suplimentar pentru a porni sau a elimina o țintă urmărită. Particulele se grupează în mod automat în jurul celei mai bune ipoteze, imediat ce banda devine vizibilă, și banda este validată cam în 2-3 cadre.

2. În cazul manevrelor de schimbare de bandă, sistemul bazat pe particule are două avantaje care fac ca tranziția să fie cât mai ușoară și rapidă: capacitatea de a urmări mai multe ipoteze în același timp, și utilizarea de particule aleatoare pentru ca în fiecare moment să putem urmări noi ipoteze. Particulele aleatoare vor inițializa un nou grup, iar datorită mișcării vehiculului către noua bandă, noul grup va primi tot mai multe particule, pe când vechea bandă va fi treptat lăsată în urmă. Când schimbarea de bandă este finalizată, noua bandă este deja urmărită de mult.

3. Situațiile de despărțire sau unire a benzilor sunt tratate în același fel ca schimbările de bandă. Sistemul este întotdeauna pregătit să urmărească o bandă nouă, care are șanse mai mari de a fi cea corectă.

4. Schimbările bruște de curbură sunt tratate sau prin generarea ipotezelor corecte suficient de rapid pentru a ține pasul cu schimbarea, similar cu situațiile 2 și 3. Dacă acest lucru nu este posibil, datorită severității condițiilor, sistemul își va reveni foarte repede după ce discontinuitatea a trecut. În ambele cazuri, estimările false sunt evitate.

5. Datorită faptului că nu există o resetare a procesului de urmărire la filtrul de particule, problemele senzorilor sunt tratate în mod uniform, indiferent de cauza și durata lor. Particulele se vor împrăștia cât timp nu avem informație de măsură, iar când aceste informații devin din nou disponibile, particulele se vor grupa din nou.

O comparație calitativă între metoda descrisă în acest capitol și o metodă bazată pe filtrul Kalman este prezentată în fișierul video *pf-kf.avi*. În partea din stânga sunt prezentate rezultatele filtrului de particule, iar în partea dreaptă rezultatele filtrului Kalman.




Fig. 10. Exemple de cadre din comparația dintre filtrul de particule și filtrul Kalman [13].
Stânga – filtrul de particule. Dreapta – filtrul Kalman.

4.2. Evaluarea acurateții estimării unghiului de aplecare

Pentru a evalua rezultatele metodei de estimare a unghiului de aplecare prezentată în acest capitol, a fost folosită o secvență de imagini în care acest unghi variază puternic. Geometria drumului forțează autovehiculul să varieze unghiul în intervalul dintre -3 și +4 grade. Deoarece nu avem o valoare cunoscută pentru acest unghi, vom compara rezultatul cu unghiul estimat prin simpla mediere a punctelor 3D dintr-o zonă restrânsă din fața autovehiculului. Zona selectată nu conține obstacole pentru întreaga durată a secvenței, astfel că punctele 3D localizate aici sunt doar puncte de pe drum. Algoritmul propus nu beneficiază de lipsa obstacolelor în zona de test, pentru că el folosește punctele din întreaga scenă, care conține suficiente puncte de obstacol.

Graficul din figura 11 arată cele două valori ale unghiului de aplecare (calculat în grade) pentru fiecare cadru din secvență. Rezultatele algoritmului prezentat sunt redată cu linie punctată, iar valoarea “reală” calculată din regiunea restrânsă este prezentată cu linie continuă albastră. Diferența dintre cele două valori este prezentată cu linie continuă verde. Din grafic se vede clar că unghiurile estimate urmează aceeași tendință. Erorile sunt cauzate de erori în reconstrucția stereo, care pot afecta ambele metode.

Comportamentul estimatorului unghiului de aplecare se poate vedea în fișierul video *pitching.avi*, unde proiecția laterală a scenei 3D și a suprafeței benzii de circulație este suprapusă pe imaginea perspectivă. Profilul orizontal nu este detectat perfect, deoarece delimitatorii de bandă sunt foarte slabi iar lățimea benzii este mai mare decât limita acceptată de algoritm (6 metri).




Fig. 11. Evaluarea preciziei estimării unghiului de aplecare [13].

4.3. Evaluarea performanței pe scenariu de autostradă

Performanța algoritmului de urmărire a benzilor a fost evaluată pentru scenariul de autostradă folosind o secvență de 2644 cadre, achiziționate la o rată medie de 10 cadre pe secundă, ceea ce înseamnă aproximativ 4.4 minute de condus. Rata de achiziție nu este constantă, dar fiecare cadru este marcat cu timpul de achiziție măsurat cu precizie de milisecundă, iar algoritmii sunt capabili să funcționeze la o rată variabilă de măsură. Secvența conține schimbări de bandă, ieșiri și intrări de pe autostradă, și vizibilitate deficitară datorită ploii și ștergătoarelor de

parbriz. În figurile 12 ... 15 se poate vedea estimarea unor parametri ai benzii (lățime, curbură, deplasament lateral și unghi de orientare, parametrii profilului vertical). Validitatea detecției este prezentată ca un semnal binar, o valoare înaltă însemnând estimare validată. Numărul cadrelor marcate ca valide este 2585, ceea ce înseamnă o rată de detecție de 97.77 %.

Secvența și rezultatele detecției, în proiecție perspectivă și în vedere de sus, pot fi vizualizate în fișierul video *highway.avi*. Punctele mov din vederea de sus sunt punctele 3D calculate prin stereoviziune, marcate ca puncte de drum pe baza unghiului de aplecare detectat.




Fig. 12. Rezultate pe autostradă: lățimea estimată (în mm) pentru fiecare cadru [13].




Fig. 13. Rezultate pe autostradă: curbura orizontală (în m^{-1}) pentru fiecare cadru [13].




Fig. 14. Rezultate pe autostradă: poziția laterală (distanța vehiculului față de centrul benzii, în mm) pentru fiecare cadru [13].




Fig. 15. Rezultate pe autostradă: unghiul de orientare (în grade) pentru fiecare cadru [13].

4.4. Evaluarea performanței în scenariu urban

Performanța algoritmului de urmărire în oraș este evaluată pe o secvență de 1763 cadre, capturate la 10 cadre pe secundă (în medie), aproximativ 3 minute de condus. Secvența conține schimbări de bandă, despărțire și unire de benzi, trecere prin tunel și treceri prin intersecții. Figurile 16...19 arată evoluția unor parametri al benzii. Validitatea detecției este de asemenea arătată pe grafice, ca semnal binar. Numărul cadrelor cu bandă validată este de 1559, ceea ce indică o rată de detecție de 88.43%. Prezența tunelului cu slabă vizibilitate în secvență este principalul motiv pentru scăderea ratei de detecție. Secvența și rezultatele detecției pot fi văzute în fișierul video *urban.avi*. O altă secvență, unde se pot vedea marcaje de calitate foarte slabă și multe obstacole se poate vedea în fișierul *crowded.avi*.




Fig. 16. Rezultate în oraș: lățimea (în mm) pentru fiecare cadru [13].




Fig. 17. Rezultate în oraș: curbura orizontală (în m^{-1}) pentru fiecare cadru [13].




Fig. 18. Rezultate în oraș: poziția laterală (în mm) pentru fiecare cadru [13].




Fig. 19. Rezultate în oraș: unghiul de orientare (în grade) pentru fiecare cadru [13].

4.5. Un model experimental: banda cu lățime variabilă liniar

Datorită faptului că mecanismul filtrului de particule este foarte adaptabil, se pot încerca ușor noi modele geometrice ale benzii de circulație. Adăugarea unui parametru de variație a lățimii, care descrie modul în care lățimea crește sau scade cu distanța Z , necesită doar schimbarea funcției care calculează coordonata laterală X pe baza distanței (profilul orizontal). Sistemul experimental rezultat a fost testat pe secvența de autostradă, în zonele de intrare și ieșire, unde lățimea benzii variază rapid și evident. Rezultatul poate fi vizionat din fișierul *varwidth.avi*.

Un grafic al estimării variației lățimii, comparată cu derivata lățimii față de spațiul parcurs, este prezentat în figura 20. Variația estimată ca parametru a modelului drumului este funcția cea mai netedă.




Fig. 20. Comparație între lățimea estimată ca parametru a modelului drumului și derivata lățimii față de spațiul parcurs [13].

4.6. Performanța de timp

Performanța de timp a algoritmului a fost evaluată pe un procesor Intel Core2 Duo de 2 GHz, pe un singur fir de execuție. Timpul de execuție este compus dintr-o parte de preprocesare a

datelor de măsură, care nu depinde de numărul de particule, și care durează 9.6 ms, și un timp de execuție pe particulă de 0.0075 ms. Pentru 200 de particule, timpul total de procesare este de 11 ms.

5. Concluzii

În acest capitol a fost descris un sistem de urmărire a benzilor de circulație care combină avantajele stereoviziunii cu cele ale procesării imaginilor de intensitate, prin intermediul unui mecanism de estimare probabilistică bazat pe filtrul de particule. Scopul principal al acestui sistem este de a aborda în mod robust situațiile dificile, discontinue. Sistemul propus nu folosește inițializare în sensul tradițional, nu există detecție preliminară a țintei sau pierdere a acesteia, și astfel timpul de procesare este constant indiferent de scenariu. Mai mult, sistemul este capabil să se adapteze rapid la schimbări, dar și să arate stabilitate atunci când măsurătorile sunt de calitate.

Sistemul poate fi extins prin adăugarea de indicii de măsurătoare, pentru îmbunătățirea stabilității și a acurateței. Indicii precum orientarea gradientilor din imagine, sau clasificarea pixelilor pe baza texturii și a intensității lor, sau posibila utilizare a imaginilor color, pot să crească precizia estimării parametrilor, dar și să extindă scenariile în care algoritmul va funcționa cu succes. Modelul estimat poate fi și el extins, după cum a fost dovedit deja, prin includerea de noi parametri precum variația curburii sau prin adăugarea de benzi laterale, care ar putea crește stabilitatea estimării în cazul schimbărilor de bandă.

Adăugarea de noi metode de măsură poate fi benefică pentru calitatea estimării, dar poate duce și la creșterea timpului de procesare, iar adăugarea de noi parametri poate crește generalitatea modelului, dar poate introduce și instabilitate. Un echilibru între toate aceste deziderate trebuie urmărit permanent.

6. Bibliografie

- [1] E.D. Dickmanns, B.D. Mysliwetz, "Recursive 3-d road and relative ego-state recognition", IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 14, no.2, 1992, pp. 199-213.
- [2] R. Aufrere, R. Chapuis, F. Chausse, "A model-driven approach for real-time road recognition", Machine Vision and Applications, vol. 13, no. 2, 2001, pp. 95-107.
- [3] S. Nedeveschi, R. Schmidt, T. Graf, R. Danescu, D. Frentiu, T. Marita, F. Oniga, C. Pocol, "3D Lane Detection System Based on Stereovision", 2004, pp. 161-166.
- [4] R. Labayrade, J. Douret, D. Aubert, "A Multi-Model Lane Detector that Handles Road Singularities", IEEE Intelligent Transportation Systems Conference, 2006, pp. 1143-1148.
- [5] B. Southall, C.J. Taylor, "Stochastic road shape estimation", IEEE International Conference on Computer Vision, 2001, pp. 205-212.
- [6] M. Isard, A. Blake, "CONDENSATION – conditional density propagation for visual tracking", International Journal of Computer Vision, vol. 29, nr. 1, 1998, pp. 5-28.
- [7] K. Macek, B. Williams, S. Kolski, R. Siegwart, "A Lane Detection Vision Module for Driver Assistance", IEEE/APS Conference on Mechatronics and Robotics, 2004.
- [8] U. Franke, H. Loose, C. Knoeppel, "Lane Recognition on Country Roads", IEEE Intelligent Vehicles Symposium, 2007, pp. 99-104.
- [9] P. Smuda, R. Schweiger, H. Neumann, W. Ritter, "Multiple Cue Data Fusion with Particle Filters for Road Course Detection in Vision Systems", IEEE Intelligent Vehicles Symposium, 2006, pp. 400-405.

- [10] Z. Kim, "Robust Lane Detection and Tracking in Challenging Scenarios," IEEE Transactions on Intelligent Transportation Systems, vol. 9, no. 1, 2008, pp. 16-26.
- [11] R. Danescu, S. Nedevschi, M.M. Meinecke, T.B. To, "Lane Geometry Estimation in Urban Environments Using a Stereovision System", IEEE Intelligent Transportation Systems Conference, 2007, pp. 271-276.
- [12] F. Oniga, S. Nedevschi, M.M. Meinecke, T.B. To, "Road Surface and Obstacle Detection Based on Elevation Maps from Dense Stereo", IEEE Intelligent Transportation Systems Conference, 2007, pp. 859-865.
- [13] R. Danescu, S. Nedevschi, "Probabilistic Lane Tracking in Difficult Road Scenarios Using Stereovision", IEEE Transactions on Intelligent Transportation Systems, vol. 10, nr. 2, 2009, pp. 272-282.

III. Urmărirea obiectelor folosind particulele

1. Introducere

Urmărirea obiectelor de tip obstacol reprezintă o funcție esențială a unui sistem senzorial proiectat pentru asistența conducerii autovehiculelor. În situații complexe, întâlnite în traficul auto real, aceste sisteme trebuie să fie capabile de a urmări mai multe obstacole în același timp.

Multe sisteme de urmărire se bazează pe formalismul matematic al filtrului Kalman, un algoritm care oferă consistență și eficiență computațională în tratarea problemelor urmăririi, precum predicția, asocierea datelor la obiectele prezise, și actualizarea stărilor pe baza măsurătorilor. Folosirea filtrului Kalman pentru urmărire este prezentată în multe lucrări științifice, cea mai reprezentativă fiind [1].

Metodele bazate pe filtrul de particule sunt de factură mai recentă, și au început să fie folosite mai ales în domeniul urmăririi vizuale, unde sursa principală de informație este camera video. Informația video are anumite avantaje asupra senzorilor clasici precum radarul sau laserul, avantaje precum bogăția de informație, oferirea de detalii asupra formei obiectului, dar are și dezavantaje precum lipsa informației directe asupra poziției și vitezei, sau, atunci când aceste informații sunt prezente (precum în cazul stereoviziunii), erorile mari asociate. Filtrul bazat pe particule este bine adaptat la surse de informație ambiguă sau zgomotoasă, precum informația vizuală, deoarece are, cel puțin teoretic, capacitatea de a urmări mai multe ipoteze în același timp, pentru că densitatea de probabilitate aproximată prin particule poate fi multimodală. Totuși, capacitatea de a urmări mai multe ipoteze în același timp nu face ca filtrul de particule să poată urmări în mod natural mai multe obstacole simultan, deoarece particulele au tendința de a se agrega în jurul celei mai puternice ipoteze, și în final rezultatul va fi un singur obiect.

Pentru a rezolva problema urmăririi de mai multe obiecte folosind filtrul de particule, o soluție este cea descrisă în [2], care modelează și urmărește întreaga configurație a scenei, incluzând probabilitatea creării unui obiect sau a eliminării acestuia din scenă. Totuși, un model prea complex duce la necesitatea folosirii de multe variabile de stare, și necesită multe particule pentru estimarea lui. În acest capitol vom descrie o alternativă mai simplă, și mai eficientă computațional, care poate fi utilizată în mai multe domenii aplicative.

Flexibilitatea filtrului bazat pe particule poate duce la multiple moduri în care datele senzoriale și modelul obiectului sunt combinate, spre deosebire de filtrul Kalman, care de obicei necesită algoritmi complecși de detecție, și asocierea exactă a datelor măsurate cu obiectele. Filtrul bazat pe particule folosește informații simple: în [3] informația senzorială este formată din muchiile detectate din imagine, iar în [4] se fuzionează informații precum simetria, muchiile, și intensitatea pixelilor imaginii. De fapt, folosirea unui filtru bazat pe particule poate substitui etapa de procesare avansată a datelor senzoriale primare, precum se arată în [5], unde se realizează reconstrucție stereo 3D prin folosirea particulelor care găsesc obiecte corespondente între cele două imagini ale perechii.

2. Vedere de ansamblu asupra soluției

În continuare va fi descrisă o metodă de urmărire a mai multor obiecte din scenă, folosind un filtru de particule organizate pe două nivele. Metoda a fost publicată de autor într-un articol de conferință [9], iar unele figuri sunt preluate din acest articol.

În primul nivel se utilizează un filtru bazat pe particule care va porni de la o densitate de probabilitate inițială care acoperă tot spațiul valorilor parametrilor obiectelor de urmărit, și care va utiliza informația 3D pentru a pondera particulele distribuite uniform prin toată scena. În timp, particulele tind să se aglomereze în jurul unui singur obiect. Când particulele sunt agregate, starea acestora este transmisă mai departe unui urmăritor individual, care va urmări obiectul până la ieșirea acestuia din scenă. În același timp, filtrul de particule de la primul nivel se va re-inițializa și va căuta un alt obiect.

Această schemă de urmărire este simplă și eficientă, și poate fi adaptată la mai multe forme de informație 3D, și la mai multe modele de obiecte. Implementarea care va fi descrisă mai departe se bazează pe identificarea zonelor de tip obstacol prin procesarea hărților de înălțimi derivate din stereoviziune, o metodă care este descrisă în detaliu în [6]. Orice altă sursă de generare a hărților de înălțimi, precum senzorii laser Velodyne [7], poate fi folosită fără mari modificări.

Sistemul de urmărire a obiectelor multiple este organizat într-o manieră distribuită, descentralizată (fig. 1). Există N sisteme de urmărire individuale, ce se bazează pe mecanismul de filtrare folosind particulele descris în [3], și un sistem similar folosit pentru inițializare. Toate sistemele de urmărire folosesc același model de obiect, același tip de particule și același tip de date de măsură.

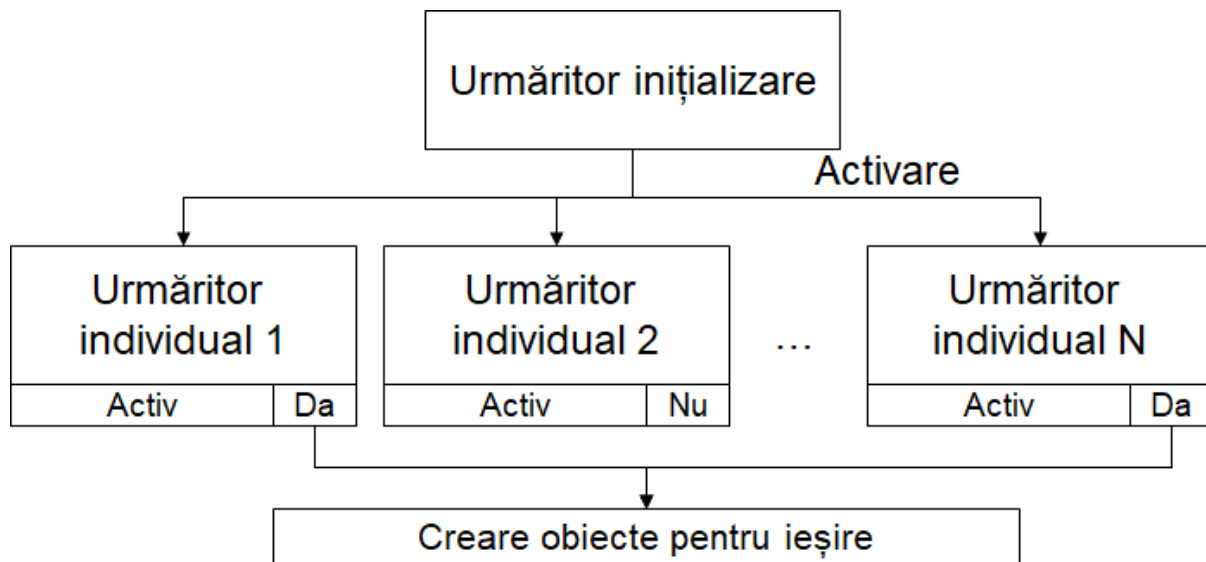


Fig. 1. Arhitectura sistemului de urmărire.

Sistemul de inițializare începe prin a genera ipoteze obiect aleatoare ce acoperă tot spațiul 3D măsurat (se va specifica un interval de variație a poziției obiectelor în faza de inițializare). Mecanismul filtrării bazate pe particule va face ca în scurt timp ipotezele să se grupeze în jurul unui singur obiect. Monitorizând distribuția particulelor, putem decide când acestea sunt grupate suficient, și, în acest moment vom prelua un urmăritor individual inactiv și îi vom transmite distribuția particulelor, activându-l. Sistemul de urmărire pentru inițializare va genera o nouă distribuție aleatoare de particule, iar obiectul găsit va fi urmărit mai departe de urmăritorul individual recent activat.

Deși urmăritoarele individuale, și urmăritorul de inițializare sunt construite pe baza aceluiași tip de filtru de particule, comportamentul lor este diferit. În figura 2 se arată comportamentul

pentru următorul de inițializare. Vom prezenta în continuare o descriere scurtă a fiecărui bloc din diagramă:

Reeșantionare (Resample) – procesul care transformă o mulțime de particule ponderate, care descriu densitatea de probabilitate anterioară, într-o mulțime de particule echivalent, dar fără ponderi, prin extragerea aleatoare a particulelor, ponderea lor influențând șansa de a fi extrase.

Generarea particulelor de inițializare – o parte a particulelor din mulțimea re-eeșantionată va fi extrasă din distribuția de probabilitate inițială, adică din întreg domeniul de stări ale obiectelor. Aceste particule vor ajuta sistemul de urmărire să iasă abandoneze rapid o ipoteză falsă, evitând blocajul.

Deplasare (Drift) – în acest pas se aplică modelul de mișcare uniform (cu viteză constantă) la toate particulele. Mai multe detalii sunt prezentate în secțiunea următoare.

Difuzie (Diffusion) – se va aplica o corecție aleatoare asupra fiecărei variabile de stare a fiecărei particule. Această corecție va ilustra incertitudinea procesului de tranziție a stării obiectelor, sau cât de mult ne așteptăm ca obiectele să devieze de la modelul de mișcare uniform.

Măsurătoarea (Measurement) – procesul prin care fiecare particulă va fi comparată cu datele de măsură, și ponderată pe baza unui scor de potrivire. Procesul este detaliat în secțiunea 5.

Estimarea (Estimation) – procesul prin care se generează o stare medie pentru un obiect, prin medierea ponderată a particulelor unui următor individual. În acest pas se va calcula și o deviație standard pentru fiecare parametru al obiectului estimat.

Decizia asupra grupării – Următorul de inițializare va folosi deviația standard calculată pe baza poziției particulelor componente pentru a decide dacă acestea sunt grupate. Dacă nu sunt grupate, următorul va continua cu un nou ciclu reeșantionare-măsurare. Dacă particulele sunt grupate, toată distribuția de particule este transmisă unui următor individual, care este activat, iar următorul de inițializare este repornit.

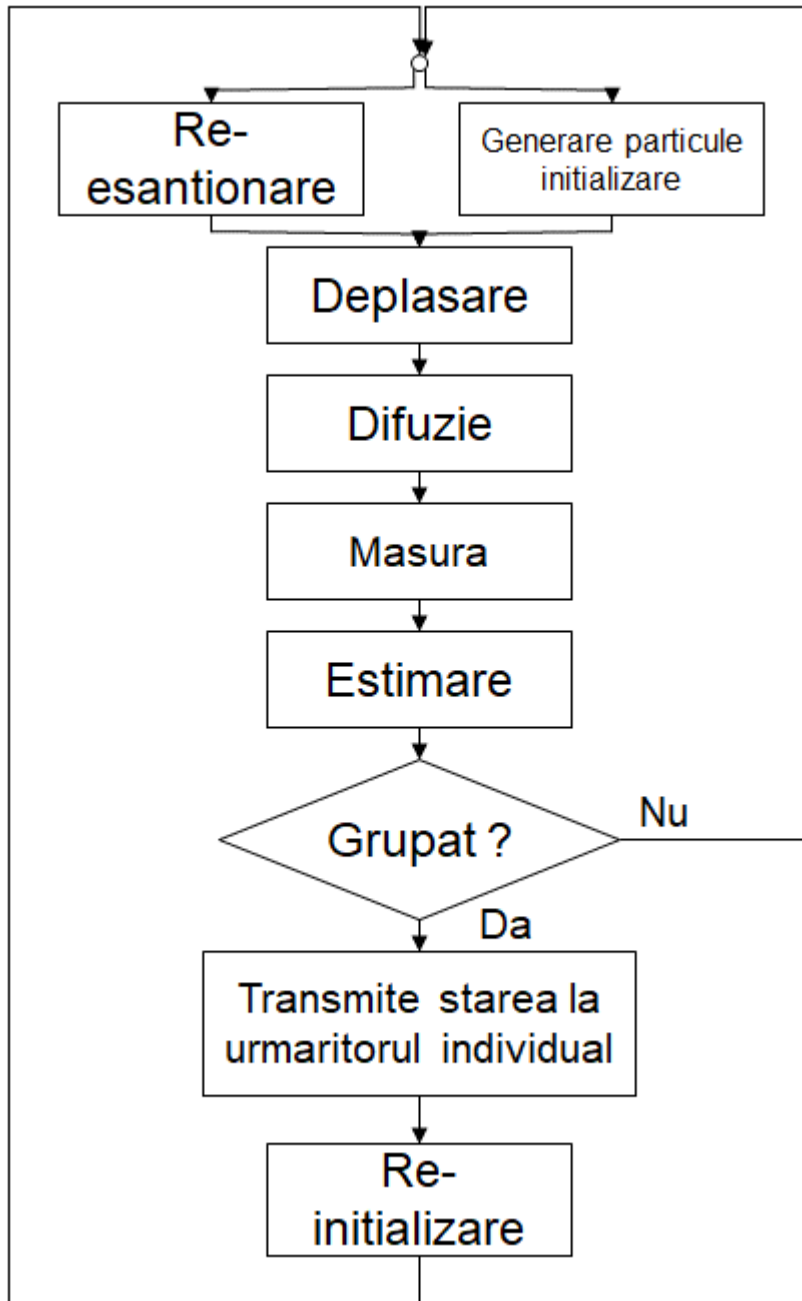


Fig. 2. Algoritm de funcționare a sistemului de urmărire pentru inițializare.

Funcționarea unui urmăritor individual activ este prezentată în figura 3. Blocurile componente sunt similare cu cele ale urmăritorului de inițializare, dar există anumite diferențe semnificative. În primul rând, nu există particule de inițializare, deoarece aceste urmăritoare operează la nivel local, iar ținta lor este deja selectată. În al doilea rând, după estimare există o condiție numită “valid”, care testează gruparea particulelor, poziția și dimensiunea obiectului (dacă crește prea mare sau devine prea mic, sau iese din câmpul vizual, el devine invalid). Dacă urmăritorul devine invalid, el intră în starea inactivă și obiectul urmărit este declarat pierdut.

Urmăritorul individual activ are și sarcina de a crea un obiect rezultat, pentru vizualizare și pentru transmiterea către alte module de asistență a conducerii. Ieșirea sistemului este formată din parametrii estimați ai obiectului și deviația lor standard calculată.

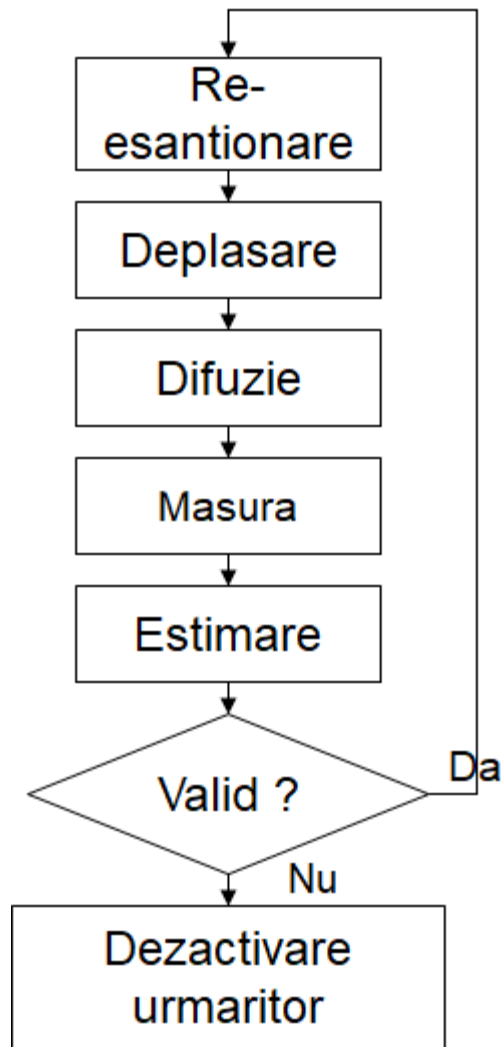


Fig. 3. Algoritm de funcționare a sistemului de urmărire pentru un obiect individual.

3. Modelul obiectelor

Și următorul de inițializare, și urmăritoarele individuale folosesc același model de obiect, și aceeași metodă de reprezentare a probabilității stării acestuia. Densitatea de probabilitate a stării obiectului este descrisă la un anumit timp t de o mulțime de N particule ponderate, $p(\mathbf{x}) \approx \{\mathbf{x}_i^i, \pi_i^i, i = 1 \dots N\}$. Valoarea particulei, \mathbf{x} , este o ipoteză asupra stării obiectului, sub forma unui vector descriptor:

$$\mathbf{x}_i = \begin{bmatrix} P_x - \text{poziția pe axa } X \\ P_z - \text{poziția pe axa } Z \\ S_x - \text{latimea pe axa } X \\ S_z - \text{lungimea pe axa } Z \\ v_x - \text{viteza pe axa } X \\ v_z - \text{viteza pe axa } Z \end{bmatrix} \quad (1)$$

Semnificația parametrilor obiectului este ilustrată în figura 4. Obiectele sunt modelate în planul XOZ (vedere de sus asupra planului drumului), fără a utiliza și înălțimea, pe axa Y. Originea sistemului de coordonate este pe drum, pe axa mediană a vehiculului nostru din care facem observațiile, în cel mai avansat punct al proiecției caroseriei noastre pe planul drumului.




Fig. 4. Parametrii obiectului urmărit [9].

Modelul dinamic al obiectului descrie modul în care starea obiectului evoluează în timp, și este redat de ecuația 2. Ecuația de evoluție a stării este folosită în faza de deplasare (drift) și difuzie, care ambele sunt parte a predicției stării.

$$\bar{\mathbf{x}}_t^i = \mathbf{A}_t \hat{\mathbf{x}}_{t-1}^i + \mathbf{w}_t \quad (2)$$

$$\mathbf{A}_t = \begin{bmatrix} 1 & 0 & 0 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & 0 & 0 & \Delta t \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (3)$$

Deplasarea deterministă este exprimată prin înmulțirea matriceală, care în cazul nostru descrie mișcarea uniformă a punctului central al obiectului, și presupune că ceilalți parametri sunt statici (dimensiune și viteză). Matricea \mathbf{A}_t depinde de timpul dintre două măsurători, Δt .

În afară de deplasamentul determinist, fiecare particulă este modificată cu o valoare aleatoare \mathbf{w}_t , extrasă dintr-o distribuție Gaussiană cu media zero și o matrice de covarianță \mathbf{Q}_t . Matricea

de covarianță Q_t este obținută prin scalarea unei matrice cu valori fixe, Q_0 , calibrată pentru un interval de timp de 100 ms între cadre, cu timpul real dintre cadre (deoarece timpul între cadre poate să nu fie fix).

4. Datele de măsură

Algoritmul pentru detecția obstacolelor și a suprafeței drumului, prezentat în [6], a fost utilizat pentru a calcula o hartă de ocupare binară preliminară. Acest algoritm folosește o hartă digitală de înălțimi pentru a reprezenta datele 3D obținute prin stereoviziunea densă într-o formă compactă, potrivită pentru procesarea în timp real.

O regiune de interes, vedere de sus a suprafeței drumului de dimensiune 40x13 metri a spațiului 3D din fața noastră, este reprezentată ca hartă de înălțimi. Această hartă este o grilă dreptunghiulară (matrice) de celule, iar valoarea de înălțime a unei celule este proporțională cu înălțimea celui mai înalt punct 3D din ea.



Fig. 4. O scenă de trafic urban [9].

Celulele unei hărți de înălțimi sunt filtrate pentru a îmbunătăți conectivitatea dintre ele și pentru a minimiza erorile de măsură, iar apoi pe baza celor mai joase înălțimi se va estima suprafața drumului. Pentru o scenă descrisă în figura 4, etapele procesării hărților de înălțimi sunt prezentate în figura 5. Pe baza estimării suprafeței drumului (figura 5, b, zonele albastre) se va estima înălțimea relativă a celorlalte celule față de drum, iar ele sunt etichetate ca zone de drum, bordură/trotuar (zonele galbene), sau obstacol (zonele roșii).

Pentru algoritmul de urmărire a obstacolelor, vom utiliza zonele etichetate ca obstacol. Din ele vom genera o hartă binară de ocupare, prezentată în figura 5,c.

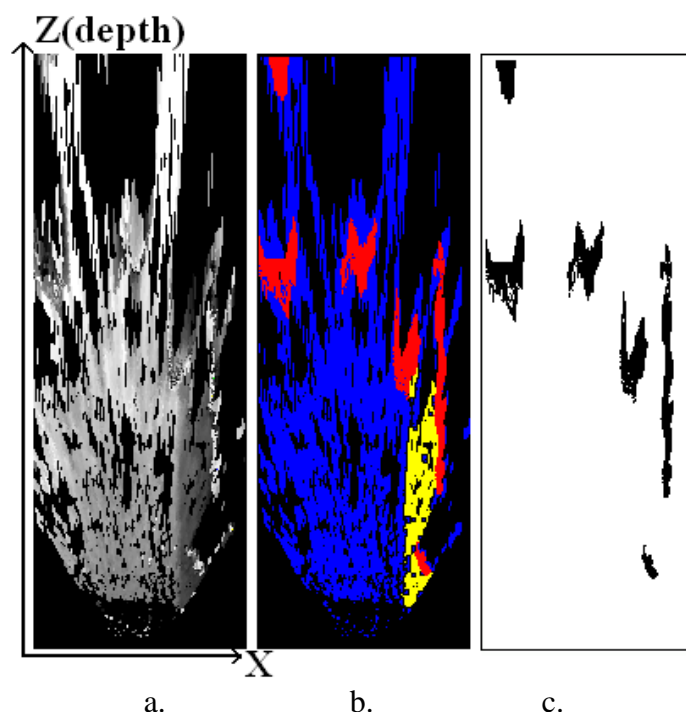


Fig. 5. Procesarea prin hărți de înălțimi a scenei prezentate în figura 4: a - Harta de înălțimi, cu intensitatea proporțională cu înălțimea, b – celulele hărții, clasificate în celule de drum, celule de trotuar/bordură și celule obstacol (albastru, galben, roșu), c – harta binară de ocupare (celulele obstacol sunt negre) [9].

5. Ponderarea particulelor folosind măsurătoarea

Algoritmul de procesare a hărților de înălțimi ne oferă o hartă binară, vedere de sus a scenei 3D, unde fiecare celulă obstacol are culoarea neagră (valoare 0), iar fiecare celulă liberă este albă (valoare 255). Scopul nostru este de a compara fiecare particulă (ipoteză a unui obiect) cu datele de măsură, și să calculăm o pondere care să reflecte gradul de potrivire.

Primul pas este să proiectăm starea particulei în spațiul măsurătorilor, o sarcină care nu este foarte dificilă deoarece spațiul de măsură este doar o variantă discretă și scalată a spațiului 3D.

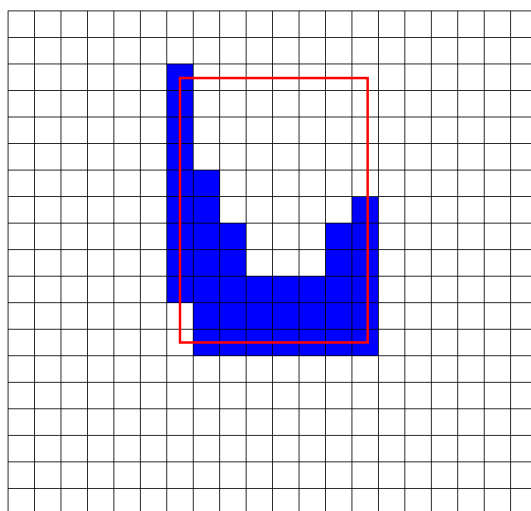


Fig. 6. O ipoteză obiect comparată cu datele de măsură [9].

Provocarea în acest moment este de a găsi o metrică de comparație suficient de bună pentru a reda diferitele grade de potrivire parțială sau totală, exactă sau aproximativă, iar această metrică să fie și suficient de rapidă pentru a permite calculul în timp real pe sute sau mii de ipoteze.

Pentru aceasta, vom selecta pentru fiecare colț al ipotezei proiectate în spațiul de măsură șase puncte, care vor fi comparate cu datele de măsură. Trei puncte sunt selectate de pe conturul proiectat, iar aceste puncte vor fi numite puncte interioare (punctele negre din figura 7). Alte trei puncte sunt alese dintr-un perimetru exterior conturului proiectat, iar aceste puncte sunt numite puncte exterioare (punctele gri din figura 7). O potrivire perfectă dintre ipoteza obiect și datele de măsură se produce dacă toate punctele interioare se potrivesc pe zone de tip obstacol din harta de ocupare binară, iar punctele exterioare se potrivesc pe zone libere.




Fig. 7. Punctele interioare și exterioare ale colțurilor ipotezei obiect proiectate în spațiul datelor de măsură [9].

Pentru a calcula scorul general de potrivire, vom atașa pentru fiecare punct $P_{i,k}^T$ (valoarea lui i este de la 1 la 4, numărul colțurilor, valoarea lui k este de la 1 la 3, numărul punctelor dintr-un colț, iar T este tipul punctului, I pentru interior și O pentru exterior) valoarea 0 dacă punctul cade pe o celulă de tip obstacol din harta de ocupare, și 255 dacă punctul cade pe o celulă liberă. Apoi vom calcula următoarele valori pentru fiecare colț:

$$I_i = \frac{1}{3} \sum_{k=1}^3 P_{i,k}^I \quad (4)$$

$$O_i = \frac{1}{3} \sum_{k=1}^3 P_{i,k}^O \quad (5)$$

Măsura de distanță pentru fiecare colț este definită de ecuația următoare:

$$D_i^2 = I_i^2 + (255 - O_i)^2 \quad (6)$$

Măsura finală pătratică a potrivirii unui colț este dată de media distanțelor pătratice ale fiecărui colț:

$$D^2 = \frac{1}{4} \sum_{i=1}^4 D_i^2 \quad (7)$$




Fig. 8. Potrivirea ipotezei cu datele de măsură [9].

Un exemplu de potrivire a colțurilor ipotezei obiectului cu datele de măsură este prezentat în figura 8. Valorile de potrivire pătratică pentru fiecare colț, începând din colțul stânga sus și mergând în sensul acelor de ceasornic, sunt: 7225, 7225, 0, 65025. Măsura de potrivire pătratică pentru întreg obiectul este 19868.75.

Acum că avem măsura de distanță (sau de potrivire), putem să calculăm ponderea particulei folosind ecuația densității Gaussiene de probabilitate, care va asigura o pondere maximă pentru distanța de potrivire minimă:

$$\pi = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{D^2}{2\sigma^2}} \quad (8)$$

Valoarea lui σ este stabilită experimental. O valoare prea mare duce la o convergență lentă a algoritmului, aglomerarea particulelor spre un obiect producându-se foarte lent. O valoare prea mică duce la un comportament de tip totul sau nimic, particulele care se potrivesc exact fiind ponderate cu valori mari, iar cele care sunt foarte puțin deviate vor primi ponderi apropiate de zero, iar acest lucru nu favorizează aglomerarea particulelor în jurul ipotezei, algoritmul putând rula fără a ajunge vreodată la un rezultat.

În funcție de poziția obiectului față de câmpul vizual al camerei, unele colțuri nu pot fi vizibile. De fapt, doar maxim trei colțuri pot fi vizibile la un moment dat, și doar aceste colțuri trebuie comparate cu datele de măsură. Colțurile vizibile sunt decise înainte de comparația propriu

zisă, pe baza poziției ipotezei: dacă poziția este centrală față de câmpul vizual al observatorului, vom compara doar cele mai apropiate două colțuri, iar dacă obiectul este într-o poziție laterală vom adăuga și un al treilea colț în listă.

La calculul distanței de potrivire, vom lua în considerare doar colțurile vizibile. Pentru exemplul nostru de mai sus, dacă considerăm că obiectul este în dreapta noastră, vom ignora colțul din dreapta cel mai îndepărtat, și scorul de potrivire se va îmbunătăți considerabil.

În cursul execuției procesului de urmărire trebuie să ne asigurăm că următorul de inițializare nu va grupa particulele în jurul unor date de măsură care sunt deja alocate urmăritoarelor individuale. Această situație o vom preveni folosind mascarea hărții de măsură. După ce un următor individual își termină ciclul reșantionare-deplasare-difuzie-ponderare, harta de măsură este mascată în ariile acoperite de acest următor, celulele obiect deja urmărite fiind eliminate. Algoritmul de urmărire pentru inițializare va rula doar după ce urmăritoarele active și-au terminat ciclul de lucru, și va folosi datele rămase neurmărite.

Acest pas este o formă de asociere a datelor, care separă inițializarea de partea de urmărire individuală. Nu este nevoie de alte asocieri mai complexe, datorită naturii stohastice a soluției.

6. Teste și rezultate

Tehnicile de urmărire propuse au fost testate în scenarii de trafic real, unde prezența a multiple obiecte relevante este aproape întotdeauna garantată. Această tehnică experimentală a fost comparată cu o altă metodă, bazată pe gruparea trăsăturilor 3D în cuboide urmată de urmărirea prin filtrul Kalman [8], și au fost comparate rezultatele estimării poziției, dimensiunii (cu excepția înălțimii, care aici nu este estimată), și a vitezei. Rezultatele estimării acestor parametri sunt comparabile, fără un avantaj clar al unei metode asupra celeilalte.

Avantajul principal al metodei bazate pe particule este că nu necesită un proces de reconstrucție 3D a cuboidelor ca etapă preliminară înainte de urmărire, ea fiind capabilă să proceseze date aproape brute. Acesta este de fapt avantajul generic al unei metode bazate pe filtrul de particule față de o metodă bazată pe filtrul Kalman: nu necesită o procesare complexă a datelor senzoriale, care să identifice obiectele țintă înainte de urmărirea lor.

Timpul de procesare depinde de complexitatea scenei, putând ajunge și la 30 ms pe cadru (configurație PC dual core, anul 2009), dar se poate obține o creștere semnificativă a vitezei prin paralelizare.

În figurile următoare se prezintă pașii intermediari și rezultatul final pentru o secvență de test, din care am ales trei cadre semnificative, alese la 3 secunde (50 cadre) unul de celălalt (fig. 9). Datele de măsură, rezultate în urma procesării hărților de înălțimi, conțin erori și incertitudini inevitabile în cazul unui sensor stereo (fig. 10).



Fig. 9. Cadre selecționate dintr-o secvență de test, la 3 secunde unul de altul [9].




Fig. 10. Datele de măsură pentru cadrele selectate [9].

În figura 11 putem observa comportamentul particulelor urmăritorului de inițializare. Acest sistem de urmărire va avea un comportament discontinuu, definit de gruparea către un singur obiect. Când particulele sunt grupate suficient, se activează un urmăritor individual, iar particulele de inițializare devin disipate din nou.

În figura 12 observăm comportamentul urmăritoarelor individuale. La început nu există urmăritoare individuale active, dar după o vreme ele vor acoperi întreaga scenă cu grupurile lor de particule. Fiecare grup de particule este folosit pentru a estima un obiect individual, rezultatul final fiind prezentat în figura 13, în proiecție perspectivă pentru a putea fi comparat cu imaginea originală.




Fig. 11. Particulele următorului de inițializare [9].




Fig. 12. Particulele următoarerilor individuale active [9].



Fig. 13. Obiectele estimate, în proiecție perspectivă [9].

7. Concluzie și posibile extensii

Acest capitol a descris o metodă de urmărire a mai multor obiecte în mod simultan, pornind de la celule etichetate ale unei hărți de înălțimi. Acest tip de informație este o procesare minimală a informației 3D oferită de un senzor de stereoviziune, ce nu implică identificarea și delimitarea clară a obiectelor individuale. Identificarea obiectelor și urmărirea lor ulterioară se realizează prin folosirea filtrelor bazate pe particule. Folosind o metrică simplă și eficientă computațional pentru potrivirea ipotezelor, aceste filtre reușesc să identifice obiectele și parametrii de poziție, mărime și viteză ale acestora.

Principalul aspect care se poate îmbunătăți este viteza de convergență a urmăritoriului de inițializare, viteză care nu este foarte mare din cauza modului de inițializare complet aleator. O concentrare pe zonele ocupate poate să mărească viteza de convergență semnificativ. De asemenea, se pot inițializa mai multe obiecte în același timp dacă se folosește un algoritm de grupare pe particulele urmăritoriului de inițializare, identificând mai multe grupuri și astfel inițializând mai multe urmăritoare individuale.

8. Bibliografie

- [1] Y. Bar-Shalom, T.E. Fortmann, "Tracking and Data Association", Academic Press Inc., 1988.
- [2] H. Tao, S. S. Sawhney, R. Kumar, "A Sampling Algorithm for Tracking Multiple Objects", Vision Algorithms: Theory and Practice, International Workshop on Vision Algorithms, held during ICCV '99, 1999, pp. 53-68.
- [3] M. Isard, A. Blake, "CONDENSATION – conditional density propagation for visual tracking", International Journal of Computer Vision, vol. 29, nr. 1, 1998, pp. 5-28.
- [4] Y. M. Chan, S. S. Huang, L. C. Fu, P. Y. Hsiao, "Vehicle Detection under Various Lighting Conditions by Incorporating Particle Filter", IEEE Intelligent Transportation Systems Conference, 2007, pp. 534-539.
- [5] A. S. Sabbi, M. Huber, "Particle Filter Based Object Tracking in a Stereo Vision System", IEEE International Conference on Robotics and Automation (ICRA), 2006, pp. 2409-2415.

- [6] F. Oniga, S. Nedevschi, M-M. Meinecke, T-B. To, “Road Surface and Obstacle Detection Based on Elevation Maps from Dense Stereo”, Intelligent Transportation Systems Conference, 2007, pp. 859-865.
- [7] Velodyne Lidar, site web: <https://velodynelidar.com>
- [8] R. Danescu, S. Nedevschi, M.M. Meinecke, T. Graf, “Stereovision Based Vehicle Tracking in Urban Traffic Environments”, IEEE Intelligent Transportation Systems Conference, 2007, pp. 400-404.
- [9] R. Danescu, F. Oniga, S. Nedevschi, M.M. Meinecke, “Tracking multiple objects using particle filters and digital elevation maps”, IEEE Intelligent Vehicles Symposium, 2009, pp. 88-93.

IV. Folosirea particulelor pentru modelarea și urmărirea hărților de ocupare

1. Introducere

Modelarea și urmărirea mediului din traficul auto sunt sarcini cu un grad ridicat de dificultate, deoarece există multe tipuri de scenarii, cu grade diferite de ordine și de complexitate. Unele scenarii sunt bine structurate, formate din obiecte ce pot fi ușor descrise prin modele geometrice, dacă se cunosc parametrii acestora. Obstacolele pot fi modelate sub forma unor cuboide având poziție, mărime și viteză, iar delimitatorii suprafeței navigabile pot fi descriși prin curbe parametrice. Autostrada și o mare parte din zonele urbane sau rurale pot fi modelate și urmărite cu modele geometrice.

Condițiile se schimbă atunci când mediul ce trebuie urmărit este o intersecție, un centru urban aglomerat, sau un scenariu off-road. Chiar dacă unele părți ale mediului ar putea fi urmărite ca parametri ai unui model geometric, multe părți esențiale nu vor îndeplini constrângerile acestor modele. De asemenea, uneori o aplicație de asistență a conducerii are nevoie de informații statice și dinamice despre mediu înainte ca un model să fie instanțiat și urmărit, sau ar putea folosi această informație în procesul de potrivire și urmărire a modelului. Din aceste motive, sunt necesare soluții pentru reprezentarea și urmărirea mediului la un nivel intermediar.

Aceste metode intermediare de reprezentare și urmărire pot să fie bazate pe hărți de ocupare, sau direct pe urmărirea punctelor 3D (precum metoda 6D vision, prezentată în [1]), sau bazate pe primitive compacte dinamice precum stixelii [2], sau ar putea fi înlocuite prin metode de determinare a vitezei critice a obiectelor [3]. În acest capitol ne vom concentra atenția asupra hărților de ocupare.

Una dintre primele utilizări a hărților de ocupare, sub numele de hărți locale de probabilitate, este descrisă de Elfes în [4], în contextul navigației robotice bazate pe senzori de tip sonar. O altă publicație [5] a aceluiași autor dă numele final al hărților de ocupare, și descrie mecanismul de inferență pentru tratarea incertitudinilor unui senzor de distanță în calcularea probabilității pentru starea fiecărei celule. În această publicație găsim definiția hărților de ocupare: “harta de ocupare este un câmp aleator multi-dimensional ce păstrează estimări stohastice ale unor celule într-o grilă spațială”.

Primele hărți de ocupare, precum cele prezentate în lucrările [4] și [5], sunt simple hărți 2D ale mediului, fiecare celulă a hărții având atașată o probabilitate de a fi liberă sau ocupată. Totuși, pentru multe aplicații de urmărire a mediului este nevoie și de estimarea parametrilor dinamici ai mediului, cum ar fi viteza pentru fiecare celulă din grilă. Adăugând spațiul vitezelor la modelul de estimat va crește complexitatea procesului în mod semnificativ, deoarece în acest caz celulele devin interconectate. Contribuțiile lui Coué și ale colaboratorilor lui, prezentate în lucrarea [6], folosesc o hartă de ocupare 4D, unde fiecare celulă are poziție și viteză pe două axe de coordonate. Prin estimarea probabilității de ocupare în harta 4D, se vor estima de fapt și vitezele în spațiul hărții 2D.

O altă soluție pentru reprezentarea vitezelor celulelor este prezentată de Chen și colaboratorii în [7]. În loc de o reprezentare 4D, această lucrare folosește spațiul clasic 2D, dar menține pentru fiecare celulă o distribuție de viteze, sub forma unei histograme. Mecanismul de

inferență Bayesiană se bazează pe datele furnizate de senzori, dar și pe conceptul de antecedenti ai unei celule, antecedenti fiind decizi de ipotezele vitezelor din histograme.

O altă metodă de estimare a aspectului dinamic al mediului, ceva mai simplă dar mai limitată, este prezentată în lucrarea [8]. În locul estimării vitezei pentru fiecare celulă, soluția aceasta se bazează pe așa numitele “urme de ocupare”, care sunt modele specifice similare cu efectul de “motion blur” al unei camere video. Aceste modele pot fi utilizate pentru a calcula traiectoria, și deci de a estima vitezele obiectelor în mișcare. O metodă ceva mai sofisticată este prezentată în [9], unde inconsistențele din harta de ocupare statică (apărute din cauza mișcării obiectelor) sunt detectate și apoi urmărite în mod separat cu un filtru Kalman multimodel.

Am putea încerca o primă clasificare a soluțiilor dinamice de tip hartă de ocupare în soluții complet dinamice, precum cele prezentate în [6], [7] și [10], și soluții de tip hibrid static-dinamic, precum cele prezentate în [8] și [9].

Una dintre cele mai importante trăsături ale unui algoritm de urmărire bazat pe hărți de ocupare este felul în care modelul probabilist al sensorului este folosit pentru actualizarea hărții estimate. Cel mai eficient mod de actualizare a unei hărți de ocupare este prin folosirea modelului invers al sensorului, care derivă probabilitatea ca o celulă să fie ocupată direct din datele senzoriale, presupunând că ocuparea unei celule este independentă de ocuparea vecinilor ei. Această soluție este încă foarte populară, mai ales în cazul hărților de ocupare statice [9]. Totuși, Thrun a arătat în [11] că modelele senzoriale directe sunt de preferat, chiar și în cazul hărților statice, deși aceste modele cresc complexitatea calculului.

Hărțile de ocupare pot avea mai multe feluri de reprezentare spațială. În lucrarea [12] găsim o comparație a trei tipuri de dispunere spațială a acestor hărți: dispunerea Carteziană (clasică, uniform distribuită de-a lungul axelor de coordonate ale planului drumului), dispunerea polară (folosind coordonatele distanță și unghi), și dispunerea de tip coloană/disparitate (folosită de obicei pentru hărțile obținute prin procesarea imaginilor stereo, unde disparitatea are o eroare liniară, spre deosebire de distanță care are o eroare ce crește rapid cu cât obiectul este mai îndepărtat). Fiecare din aceste tipuri de reprezentare are avantaje și dezavantaje. O reprezentare Carteziană este mai apropiată de lumea reală, și poate reprezenta mai ușor vitezele și deplasarea, pe când celelalte tipuri de hartă sunt mai apropiate de datele senzoriale, ușurând calculul modelelor de eroare.

Harta de ocupare este o reprezentare flexibilă a mediului, iar această flexibilitate permite integrarea informației din mai multe surse. De exemplu, se poate integra informație de tip hartă geografică, precum se arată în lucrarea [10]. Această hartă poate asocia fiecărei celule un tip de teren (precum drum, bordură, sau trotuar), iar tipul de teren determină probabilitatea ca această celulă să fie ocupată la un moment dat de un obstacol. Folosirea informației de tip teren poate îmbunătăți considerabil procesul de predicție a poziției obiectelor dinamice de pe drum.

Flexibilitatea hărților de ocupare permite de asemenea și actualizarea colaborativă (concurrentă), folosind informația de la mai mulți senzori, sau de la mai mulți observatori. O soluție care folosește harta de ocupare (numită de autori hartă de obstacole) pentru a integra informație de la senzori laser și radar este prezentată în lucrarea [13], iar în lucrarea [14] aceste hărți sunt folosite pentru a fuziona informația 3D obținută prin stereoviziune cu informație de tip flux optic (mișcarea în spațiul imagine). O soluție care integrează observațiile de la mai mulți observatori, folosind harta de ocupare pentru a obține o reprezentare unificată a mediului, este prezentată în lucrarea [15].

În continuare, acest capitol va prezenta o metodă de urmărire a mediului din traficul auto folosind o hartă de ocupare bazată pe particule. Această soluție este definită printr-o abordare originală a reprezentării probabilității de ocupare a celulelor, precum și a distribuției de probabilitate a vitezelor celulelor, și printr-un algoritm original de actualizare a hărții de ocupare, care folosește avantajele reprezentării propuse. Probabilitatea de ocupare a fiecărei celule este descrisă de numărul de particule localizate în respectiva celulă, dar aceste particule au un rol dublu: ele formează ipoteze asupra ocupării celulelor, în sensul folosit de algoritmi de urmărire bazați pe particule, precum CONDENSATION [16], dar pot fi privite și ca elementele constituente ale lumii modelate. Algoritmii de urmărire este orientat spre particulă, nu spre celulă. Particulele au poziție și viteză, și pot migra dintr-o celulă în alta pe baza modelului de mișcare uniform și a vitezei proprii, dar pot fi și create sau distruse folosind logica de ponderare-reeșantionare descrisă în [16]. Datele de măsură sunt formate din harta de ocupare primară (binară) rezultată din procesarea hărților de înălțimi, metodă descrisă în [17]. Pentru generarea unei hărți de înălțimi cu o densitate adecvată este nevoie de o metodă densă de reconstrucție stereo, care să atașeze informație 3D fiecărui punct din imagine. Metoda folosită în această lucrare este prezentată în lucrarea [18], iar alte metode de stereoviziune densă sunt prezentate în [19].

Pe baza literaturii studiate, soluția de modelare și urmărire pe care o vom prezenta în acest capitol se poate clasifica ca având o *reprezentare Carteziană*, ce folosește un *model direct de probabilitate al senzorului*, și produce o *hartă de ocupare complet dinamică*. Metoda descrisă este înrudită cu soluțiile prezentate în lucrările [7] și [10], lucrări care folosesc o distribuție a vitezelor pentru fiecare celulă din hartă, spre deosebire de modelarea aspectului dinamic ca o hartă cu mai multe dimensiuni, precum în [6]. Considerăm că soluția prezentată este o îmbunătățire adusă acestor tehnici, deoarece prin utilizarea particulelor în mișcare reprezentarea distribuției vitezelor nu mai constituie o problemă. Nu mai e nevoie să estimăm distribuția vitezelor ca o histogramă, precum în [7], sau ca o mixtură de Gaussieni, precum în [10], nu trebuie să presupunem că o celulă aparține unui singur obiect, cu un singur tip de viteză, și nici nu trebuie să ne preocupe estimarea acestei viteze în mod explicit, deoarece ea va rezulta în mod natural din supraviețuirea sau eliminarea particulelor purtătoare. Particulele dintr-o celulă pot avea diferite viteze, astfel încât ele pot trata și situația obiectelor suprapuse, sau, mai realist, situația obiectelor care sunt prea apropiate astfel încât incertitudinea poziției unui obiect se suprapune peste incertitudinea celuilalt.

Complexitatea algoritmului este liniară cu numărul de celule din hartă, și cu numărul maxim de particule permise a exista într-o celulă. Reglând acești parametri, se poate realiza un compromis între acuratețea estimărilor și timpul de procesare. Mai mult, dacă se dorește adăugarea unui nou parametru de mișcare, precum accelerația, complexitatea algoritmului nu va crește, deoarece se modifică doar modul în care se calculează noile poziții ale particulelor aflate în mișcare.

În continuare vom descrie modelul lumii bazat pe particule, urmând apoi să descriem pașii algoritmului de estimare: predicția, măsurătoarea și estimarea. Apoi, ca aplicație, vom arăta cum se pot extrage din harta de ocupare obiecte individuale, sub formă de cuboide cu poziție, dimensiune și viteză. Vor fi descrise și testele folosite pentru validarea metodei, și rezultatele acestora.

Rezultatele descrise în acest capitol au fost publicate inițial în articolul de jurnal [22]. Unele figuri sunt preluate din acest material publicat.

2. Modelul lumii

Lumea ce urmează a fi urmărită este reprezentată de o hartă 2D, care descrie într-o vedere de sus spațiul înconjurător din trafic, sub forma unei grile de celule de 20 cm x 20 cm. Dimensiunea totală a grilei este de 250 rânduri x 120 coloane, ceea ce corespunde unei dimensiuni a scenei observate de 50 m x 24 m. Scopul algoritmului de urmărire este de a calcula probabilitatea fiecărei celule de a fi ocupată, și componentele vitezei celulelor pe fiecare axă de coordonate. Obiectivele de urmărire a lumii sunt atinse prin intermediul unui mecanism de filtrare bazat pe particule.

Luând în considerare un sistem de coordonate unde axa z este orientată de-a lungul direcției noastre de deplasare, iar axa x este orientată spre dreapta noastră, obstacolele din lume sunt reprezentate de o mulțime de particule $S = \{p_i \mid p_i = (c_i, r_i, vc_i, vr_i, a_i), i = 1 \dots N_S\}$, fiecare particulă i având o poziție în grilă, descrisă de rândul r_i (o discretizare a coordonatei 3D z) și coloana c_i (o discretizare a coordonatei 3D x), și o viteză descrisă de componentele pe fiecare coordonată, vc_i și vr_i . Un parametru suplimentar, a_i , descrie vârsta particulei de la momentul creării sale. Scopul acestui parametru este de a facilita procesul de estimare și validare, care se vor descrie în secțiunile următoare.

Numărul total de particule din scenă, N_S , nu este fix. Acest număr depinde de gradul de ocupare al scenei, adică de numărul de celule de tip obstacol din hartă.

Având definită populația de particule, putem estima gradul de ocupare al unei celule C ca raportul dintre numărul de particule cu poziția corespunzătoare celulei C , și numărul total de particule permise într-o celulă, N_C .

$$P_O(C) = \frac{|\{p_i \in S \mid r_i = r_c, c_i = c_c\}|}{N_C} \quad (1)$$

Numărul de particule permise într-o celulă, N_C , este un parametru global al sistemului. La alegerea valorii lui trebuie făcut un compromis între acuratețea estimării și timpul de procesare. O valoare mare înseamnă că se pot păstra multe ipoteze de viteză într-o singură celulă, și deci algoritmul de urmărire va avea o estimare mai bună a vitezelor, și poate aborda mai bine obiectele cu mișcare rapidă. Pe de altă parte, numărul total de particule din scenă este proporțional cu N_C , și, în consecință, și timpul de procesare.

Viteza unei celule poate fi estimată ca viteza medie a tuturor particulelor din celula respectivă, dacă presupunem că un singur obiect se află într-o celulă. Populația de particule poate, pe de altă parte, să trateze și cazul când mai multe obstacole cu viteze diferite împart aceeași celulă, iar în acest caz viteza ar trebui estimată prin gruparea celulelor de viteză similară.

$$(vc_C, vr_C) = \frac{\sum_{p_i \in S, x_i = x_c, z_i = z_c} (vc_i, vr_i)}{|\{p_i \in S \mid r_i = r_c, c_i = c_c\}|} \quad (2)$$

Astfel, populația particulelor este o reprezentare suficient de generală pentru densitatea de probabilitate a ocupării celulelor, dar și pentru densitatea de probabilitate a vitezelor din celule. Mai multe ipoteze pot fi menținute simultan pentru o celulă, iar incertitudinea ocupării este reprezentată de numărul variabil de particule asociate unei celule.

În acest moment se poate defini obiectivul concret al algoritmului de urmărire: pe baza informației senzoriale, algoritmul va crea, va actualiza și va distruge particule pentru ca ansamblul lor să redea cât mai fidel lumea reală observată.

3. Algoritmul pe scurt

Primul pas al algoritmului de urmărire este *predicția*, care este aplicată fiecărei particule din scenă. Pozițiile particulelor sunt modificate pe baza vitezei lor și pe baza mișcării proprii a vehiculului nostru. În același timp, se adaugă o cantitate aleatoare la poziția și viteza particulei, pentru a avea un efect de difuzie stohastică.

Al doilea pas al algoritmului este *procesarea informației de măsură*. Acest pas se bazează pe harta de ocupare binară obținută prin procesarea hărților de înălțimi, și va genera *modelul de măsură* (modelul senzorial) pentru fiecare celulă. Modelul de măsură este folosit apoi pentru a *pondera* particulele și pentru a le *reeșantiona*, în același pas. Prin ponderare și reeșantionare, particulele unei celule pot fi multiplicare sau reduse.

Ultimul pas este estimarea probabilității de ocupare pentru fiecare celulă și a vitezelor corespunzătoare, și gruparea celulelor ocupate în obiecte discrete pentru evaluarea rezultatelor estimării.

4. Predicția

Acest prim pas al algoritmului de urmărire va deriva o distribuție prezentă a particulelor pe baza distribuției anterioare, pregătind mulțimea particulelor pentru măsurătoare. Ecuațiile predicției se bazează pe informația de odometrie (informația mișcării vehiculului nostru), precum și pe modelul de mișcare uniform bazat pe viteza proprie a particulelor.

Informația odometrică de bază disponibilă pe magistrala CAN a unui autovehicul modern include viteza de deplasare v și viteza de rotație angulară (*yaw rate*) $\dot{\psi}$. Acești parametri, împreună cu timpul dintre măsurători Δt , vor fi folosiți pentru a calcula mișcarea vehiculului propriu, pentru a compensa astfel mișcarea aparentă a scenei față de noi.

Între două măsurători, vehiculul se rotește cu un unghi ψ , și parcurge o distanță d :

$$\psi = \dot{\psi}\Delta t \tag{3}$$

$$d = \frac{2v\Delta t \sin \frac{\psi}{2}}{\psi} \tag{4}$$

Originea hărții de ocupare se va deplasa de-a lungul celor două axe de coordonate (coloană și rând) cu cantitățile d_c și d_r .

$$d_c = d \sin \frac{\psi}{2} / DX \quad (5)$$

$$d_r = d \cos \frac{\psi}{2} / DZ \quad (6)$$

Prin DX și DZ notăm dimensiunile celulei din harta de ocupare (în implementarea curentă acestea sunt egale, 0.2 m). Un punct în harta de ocupare, localizat pe rândul r și coloana c , va fi deplasat la noile coordonate r_n și c_n pe baza următoarei ecuații:

$$\begin{bmatrix} c_n \\ r_n \end{bmatrix} = \begin{bmatrix} \cos \psi & -\sin \psi \\ \sin \psi & \cos \psi \end{bmatrix} \begin{bmatrix} c \\ r \end{bmatrix} - \begin{bmatrix} d_c \\ d_r \end{bmatrix} \quad (7)$$

Predicția finală va fi obținută prin aplicarea ecuației 8, care combină deplasarea deterministă cauzată de compensarea mișcării vehiculului propriu și de deplasarea particulei pe baza vitezei ei proprii cu o difuzie stohastică cauzată de incertitudinile din modelul de mișcare. Cantitățile δc , δr , δv_c și δv_r sunt extrase aleator dintr-o distribuție Gaussiană de medie zero și o matrice de covarianță \mathbf{Q} echivalentă cu matricea de covarianță a tranziției stărilor de la filtrul Kalman. Matricea de covarianță este diagonală, cu deviații standard pentru viteză corespunzând unei valori din lumea reală de 1 m/s, iar deviația standard pentru poziție având corespondentul unei incertitudini de 0.1 m. Aceste valori sunt reglate în așa fel încât algoritmul să poată aborda obiectele în mișcare rapidă chiar și la o rată de măsură de 10 cadre pe secundă.

$$\begin{bmatrix} c \\ r \\ v_c \\ v_r \end{bmatrix} = \begin{bmatrix} 1 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & \Delta t \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} c_n \\ r_n \\ v_c \\ v_r \end{bmatrix} + \begin{bmatrix} \delta c \\ \delta r \\ \delta v_c \\ \delta v_r \end{bmatrix} \quad (8)$$

Din punctul de vedere al modelului hărții de particule, predicția are ca efect deplasarea particulelor dintr-o celulă în alta, după cum este ilustrat în figura 1. Probabilitatea de ocupare este astfel ajustată dinamic pe baza modelului de mișcare a particulelor și pe baza odometriei.




Fig. 1. Particulele pe hartă, înainte și după predicție [22].

5. Modelul de măsură

Modelul de măsură face legătura dintre datele de măsură (datele senzoriale), care sunt agregate într-o hartă de celule cu valoare binară (ocupat/liber) derivată din procesarea hărților de înălțimi calculate prin stereoviziune [17], și probabilitățile condiționate $p(\text{measurement} / \text{occupied})$ și $p(\text{measurement} / \text{free})$, care vor sta la baza ponderării particulelor. Pentru a putea calcula aceste valori trebuie să parcurgem mai mulți pași, care sunt descriși în secțiunile următoare.

5.1. Incertitudinea măsurărilor stereo

Primul pas în calculul probabilităților condiționate este să calculăm incertitudinea reconstrucției 3D prin stereoviziune. Incertitudinea distanței, în cazul unui sistem de camere rectificat (aliniat perfect), este dată de:

$$\sigma_z = \frac{z^2 \sigma_d}{bf} \quad (9)$$

În ecuația de mai sus, z reprezintă distanța în coordonate 3D, b este baseline-ul (distanța dintre camere) a sistemului de camere stereo, f este distanța focală exprimată în pixeli, iar σ_d este eroarea la calculul disparității (găsirea corespondenței unui punct din imaginea stângă în imaginea dreaptă), care este de obicei aproximativ 0.25 pixeli pentru un algoritm de stereoviziune bun.

Eroarea coordonatelor laterale (de obicei mult mai mică decât eroarea pe z) poate fi derivată din eroarea distanței. Această eroare depinde de poziția laterală x (în coordonate 3D) și de distanța z :

$$\sigma_x = \frac{x \sigma_z}{z} \quad (10)$$

Incertitudinile (erorile) 3D sunt transformate în incertitudini din spațiul hărții de ocupare, prin scalarea lor cu dimensiunea celulei pe coordonatele x și z .

$$\begin{aligned}\sigma_{row} &= \frac{\sigma_z}{DZ} \\ \sigma_{column} &= \frac{\sigma_x}{DX}\end{aligned}\tag{11}$$

Pentru accelerarea calculelor, valorile σ_{row} și σ_{column} sunt calculate înainte de începerea procesului de urmărire, o singură dată, în faza de inițializare a sistemului.

5.2. Indiciul densității hărții binare de ocupare

Pentru a putea calcula probabilitățile condiționate pentru o celulă măsurată, sub presupunerea că această celulă este ocupată sau liberă, trebuie să ținem cont de un fapt specific senzorilor de stereoviziune, și anume că acest senzor nu scanează scena precum un senzor laser, și astfel nu are doar o singură măsurătoare (foarte precisă) pentru o celulă din hartă. Dacă luăm drept exemplu un stâlp, acesta ar trebui să fie un obiect punctiform în harta de ocupare, el neavând o lățime sau o adâncime semnificativă. Reprezentarea acestui stâlp ar trebui să fie în harta de ocupare o singură celulă. Dacă acest stâlp ar fi detectat de un senzor laser, el ar produce un singur punct 3D, cu poziția reală deplasată puțin datorită micilor erori ale senzorului. Pentru stereoviziune lucrurile stau în mod diferit, deoarece camera observă toată înălțimea stâlpului, și astfel vom avea, pentru fiecare pixel al stâlpului, o poziție diferită pe coordonata rând (distanța) și pe coordonata coloană (poziția laterală). Atunci când vom “aplatiza” aceste coordonate în harta de ocupare, stâlpul va acoperi mai multe celule. Dimensiunea zonei ocupate va depinde de incertitudinile de măsură stereo pe cele două axe, r și c (corespunzătoare axelor x și z din lumea reală).

Această proprietate a procesului de măsură prin stereoviziune ne arată un indiciu util, care va contribui la calculul probabilităților condiționate a celulelor de măsură sub ipoteza ocupării sau eliberării lor. Vom număra celulele marcate ca obstacol din jurul poziției celulei curente, într-o zonă de înălțime $2\sigma_{row}$ și lățime $2\sigma_{column}$, și vom împărți acest număr la numărul total de celule din zona analizată. Vom nota acest raport ca $p_{density}(m(r,c) | occupied)$.

$$p_{density}(m(r,c) | occupied) = \frac{\sum_{row=r-\sigma_{row}}^{row=r+\sigma_{row}} \sum_{col=c-\sigma_{column}}^{col=c+\sigma_{column}} O(row, col)}{(2\sigma_{row} + 1)(2\sigma_{column} + 1)}\tag{12}$$

Prin $O(row, col)$ se notează valoarea “ocupat” din harta binară de măsură, la poziția row și col . Această valoare este 1 când celula este de tip obstacol, și 0 când celula este liberă.

Indiciul densității pentru presupunerea că celula este liberă este:

$$p_{density}(m(r,c) | free) = 1 - p_{density}(m(r,c) | occupied)\tag{13}$$

O comparație grafică între măsurătorile primare, din harta de măsură binară, și indiciul pe bază de densitate al ipotezei că celulele sunt ocupate (aproximarea probabilității condiționate a acestei ipoteze) este prezentată în figura următoare:




Fig. 2. De la harta de ocupare primară la indiciul densității măsurătorilor. Stânga-jos: harta de ocupare de măsură, binară. Dreapta-jos: probabilitatea bazată pe densitate pentru ipoteza celulei ocupate [22].

5.3. Tratarea ocluziilor

Nu toate celulele din hartă se pot observa în mod direct, și acest lucru trebuie luat în considerare de algoritmul de urmărire. Datorită limitărilor sursei primare de informație, harta de ocupare binară procesată din informația de stereoviziune, unele celule nu pot fi observate. Harta de măsură acoperă doar un domeniu longitudinal de la 0 la 40 de metri, și o lățime de 13 metri. De asemenea, câmpul vizual al camerei (deschiderea angulară) limitează vizibilitatea la distanțe apropiate.

Celulele care sunt invizibile datorită limitării câmpului vizual sau a razei de detecție a sistemului stereo sunt marcate în mod implicit ca acoperite (afectate de obstrucție).

Un alt mod prin care o celulă poate deveni neobservabilă este dacă ea este acoperită de un obstacol aflat între ea și cameră. Pentru a putea decide dacă o celulă este în această situație, vom utiliza coordonatele polare, și fiecare celulă va fi proiectată într-o grilă polară, cu originea în punctul de observație (în poziția camerei). Apoi, pentru fiecare unghi din spațiul polar (corespunzător unei raze care pleacă din cameră) se analizează celulele în ordinea distanțelor lor față de cameră. La găsirea unei celule ocupate, se incrementează un contor de obstrucție pentru fiecare celulă din spatele primei celule ocupate găsite. După atașarea contorului de obstrucție pentru fiecare celulă din spațiul polar, se aduc aceste valori înapoi în spațiul Cartezian.

După ce fiecare celulă are valoarea de obstrucție, se face analiza finală. Fiecare celulă care are valoarea de obstrucție mai mare decât 10 este considerată acoperită, și acest lucru se ia în considerare în faza de ponderare a particulelor și reeșantionare, ce va fi descrisă în secțiunea următoare. De asemenea, proprietatea de acoperire se folosește și pentru a elimina celule din harta de măsură. Celulele acoperite se elimină, astfel încât harta de măsură va semăna mai mult cu o hartă generată de un senzor de tip scanner. Acest pas de reducere a datelor de măsură trebuie efectuat înainte de calculul celui de-al doilea indiciu pentru ponderarea particulelor, care se bazează pe distanța celulelor față de datele de măsură.

Pașii de procesare bazați pe proprietatea de obstrucție sunt descriși în figura 3. În panoul din stânga se observă datele de măsură primare (harta binară), panoul din mijloc arată valoarea de obstrucție pentru fiecare celulă (mai luminos înseamnă cu grad de obstrucție mai mare), iar panoul din dreapta arată datele de măsură după eliminarea celulelor acoperite. Aceste date sunt folosite pentru calcularea următorului indiciu, bazat pe distanța față de măsurătoare.




Fig. 3. Abordarea ocluziilor [22]. Stânga – măsurătoarea originală, mijloc – valoarea obstrucției pentru fiecare celulă, dreapta – măsurătorile neacoperite.

5.4. Indiciul distanței față de măsurătoare

Pentru fiecare celulă din harta de ocupare vom calcula distanța față de cea mai apropiată celulă de tip obstacol din harta de măsură. Pentru găsirea celei mai apropiate celule vom utiliza o variantă modificată a algoritmului de transformare în distanță (Distance Transform), prezentat în [20]. Cea mai importantă modificare pe care trebuie să o aducem acestui algoritm este că el nu trebuie să măsoare doar distanța față de cel mai apropiat punct de măsură, ci distanța pe fiecare din cele două axe, rând și coloană. Motivul pentru care este necesară măsurarea distanțelor pe fiecare axă este că deviațiile standard pentru erorile stereo sunt diferite pe axa rând față de cele de pe axa coloană și nu pot fi interschimbate.

Algoritmul nostru modificat pentru calculul transformatei distanță parcurge aceiași pași ca algoritmul clasic bazat pe distanța L1, dar în loc de actualizarea la fiecare trecere a distanței către măsurătoarea cea mai apropiată, se va actualiza în același timp și poziția acestei măsurători. Algoritmul ce urmează va actualiza un tablou de distanțe $D(r, c)$, inițializat cu zero

pentru celulele declarate de tip obstacol în harta de măsură și cu 255 pentru celulele declarate libere, și două tablouri de poziții M_r și M_c ce păstrează poziția pe rând și pe coloană a celei mai apropiate celule ocupate. Valorile M_r și M_c sunt inițializate cu rândul și coloana proprie fiecărei celule.

Algoritm DistanceTransform

```

For  $r=1$  to  $max\_r$ 
  For  $c=1$  to  $max\_c$ 
    Update ( $r, c, -1, 0$ )
    Update ( $r, c, 0, -1$ )
  End For
End For
For  $r = max\_r$  to 1
  For  $c = max\_c$  to 1
    Update ( $r, c, 1, 0$ )
    Update ( $r, c, 0, 1$ )
  End For
End For

```

Funcție Update(r, c, n, k)

```

If  $D(r, c) > D(r+n, c+k) + 1$ 
   $D(r, c) = D(r+n, c+k) + 1$ 
   $M_r(r, c) = M_r(r+n, c+k)$ 
   $M_c(r, c) = M_c(r+n, c+k)$ 
End If

```

După aplicarea algoritmului transformare distanță, distanțele către cea mai apropiată celulă de măsură ocupată, pe linie și pe coloană, se calculează astfel:

$$d_{row}^{occupied}(r, c) = |r - M_r(r, c)| \quad (14)$$

$$d_{column}^{occupied}(r, c) = |c - M_c(r, c)|$$

Distanța la cea mai apropiată celulă liberă se calculează ca diferența dintre dublul deviației standard pentru eroarea de poziționare și distanța către celula ocupată, saturată la zero.

$$d_{row}^{free}(r, c) = \max(2\sigma_{row}(r, c) - d_{row}^{occupied}(r, c), 0)$$

$$d_{column}^{free}(r, c) = \max(2\sigma_{column}(r, c) - d_{column}^{occupied}(r, c), 0) \quad (15)$$

Aceste distanțe sunt convertite în valori de densitate de probabilitate, folosind ecuația distribuției Gaussiene multivariate (ecuația 16). Pentru a nu încălca foarte mult ecuația, am eliminat argumentele (r, c) pentru variabilele implicate. Aceeași ecuație se aplică și pentru distanțele de tip liber, cât și pentru cele de tip ocupat, iar aceste situații sunt reprezentate în ecuație sub forma genericului *status*.

$$p_{\text{distance}}(m | \text{status}) = \frac{1}{2\pi\sigma_{\text{row}}\sigma_{\text{column}}} \cdot e^{-\frac{1}{2}\left(\left(\frac{d_{\text{row}}^{\text{status}}}{\sigma_{\text{row}}}\right)^2 + \left(\frac{d_{\text{column}}^{\text{status}}}{\sigma_{\text{column}}}\right)^2\right)} \quad (16)$$

La finalul acestui proces vom avea, pentru fiecare celulă, valorile de densitate $p_{\text{distance}}(m(r,c) | \text{occupied})$ și $p_{\text{distance}}(m(r,c) | \text{free})$.

6. Ponderare și reeșantionare

Pașii unui filtru de particule clasic pentru urmărire sunt reeșantionarea, deplasarea, difuzia, și măsurătoarea (ponderarea). Acest mecanism actualizează o populație de particule, pentru a aproxima o densitate de probabilitate actualizată într-un spațiu al parametrilor de urmărit. Acest mecanism este proiectat pentru cazul când particula reprezintă o ipoteză asupra stării unui sistem. În cazul nostru particula este o ipoteză, dar este și unitatea elementară de construcție a modelului lumii noastre.

Algoritmul propus va vedea particula în forma ei duală – ca ipoteză asupra unei stări și ca element de construcție a lumii urmărite. Rolul particulelor ca elemente constructive a fost deja explicat. Totuși, dacă ne concentrăm raționamentul asupra unei singure celule din harta de ocupare, vom vedea că *particula este în același timp și ipoteză*. O particulă într-o celulă a hărții este o ipoteză că celula este ocupată, și că viteza obiectului din celulă este egală cu viteza particulei. Mai multe particule în celulă înseamnă că ipoteza că celula este ocupată este mai puternică (are o pondere mai mare). La fel, mai puține particule în celulă înseamnă că ipoteza că celula este liberă este mai puternică. Putem să considerăm diferența dintre numărul de particule permise într-o celulă (capacitatea celulei) și numărul efectiv de particule în celula respectivă ca fiind numărul de particule având ipoteza de ocupare zero.

6.1. Ponderarea particulelor

Dacă privim numărul de particule într-o celulă ca fiind constant, dar unele dintre particule au valoarea de ocupare “adevărat” iar altele “fals”, putem aplica mecanismul de ponderare și reeșantionare.

Deoarece datele de măsură sunt statice, ele neavând informații despre viteza obiectelor, ponderea particulelor va depinde doar de ipoteza asupra ocupării, și particulele din aceeași celulă care au aceeași ipoteză vor avea aceeași pondere.

Pentru fiecare celulă de la poziția r, c în hartă, ponderile pentru ipoteza liber sau ocupat sunt obținute prin fuzionarea indiciilor calculate pe baza datelor de măsură, după cum a fost descris în secțiunea 5.

$$w_{\text{occupied}}(r, c) = p_{\text{density}}(m(r, c) | \text{occupied}) \cdot p_{\text{distance}}(m(r, c) | \text{occupied}) \quad (17)$$

$$w_{\text{free}}(r, c) = p_{\text{density}}(m(r, c) | \text{free}) \cdot p_{\text{distance}}(m(r, c) | \text{free}) \quad (18)$$

Ecuțiile 17 și 18 sunt valabile doar dacă celula este observabilă, adică dacă ea nu este acoperită, conform analizei descrise în secțiunea 5.3. Dacă celula este acoperită, ponderile ipotezelor liber și ocupat vor fi egale, $w_{occupied}(r, c) = w_{free}(r, c) = 0.5$.

Numărul de particule care au ipoteza “ocupat” adevărată este egal cu numărul de particule “reale” dintr-o celulă:

$$N_{OC}(r, c) = |\{p_i \in S \mid r_i = r, c_i = c\}| \quad (19)$$

Numărul de particule (ipoteze) care au ipoteza “ocupat” cu valoarea fals este complementul lui N_{OC} . Dacă N_C este numărul maxim de particule permis într-o celulă (un parametru global al algoritmului) vom calcula numărul de ipoteze “liber” ca:

$$N_{FC}(r, c) = N_C - N_{OC}(r, c) \quad (20)$$

Densitatea de probabilitate posterioară totală pentru ipoteza că o celulă este ocupată poate fi calculată din numărul de ipoteze libere/ocupate, și ponderile lor corespunzătoare. În următoarele ecuații am omis parametrii de rând și coloană a celulei, pentru lizibilitate.

$$P_{OC} = \frac{w_{occupied} N_{OC}}{w_{occupied} N_{OC} + w_{free} (N_C - N_{OC})} \quad (21)$$

$$P_{FC} = \frac{w_{free} (N_C - N_{OC})}{w_{occupied} N_{OC} + w_{free} (N_C - N_{OC})} \quad (22)$$

Aceste ponderi agregate, P_{OC} și P_{FC} , sunt folosite în procesul de reeșantionare a particulelor. Re-eșantionarea se face după procesarea informației de măsură, astfel încât următorul ciclu de urmărire pornește cu o populație de particule actualizată, a căror pondere nu mai este relevantă deoarece a fost deja utilizată.

6.2. Reeșantionarea particulelor

Un algoritm de reeșantionare clasic ar face un număr de N_C extrageri aleatoare din populația anterioară de particule a unei celule, iar ponderea fiecărei particule ar decide șansele ca ea să fie selectată. Deoarece ipotezele de tip “celulă liberă” nu ne interesează, procesul nostru de reeșantionare va decide doar pentru particulele adevărate, cele cu ipoteza “celulă ocupată”, dacă ele vor fi eliminate sau multiplicat (și de câte ori).

Următorul algoritm descrie procesul de reeșantionare, care se materializează sub forma înmulțirii sau eliminării particulelor din mulțime. Soluția pentru o procesare în timp real este ca toate sarcinile dificile computațional să fie executate la nivel de celulă, de obicei prin tabele de valori precalculate, procesarea la nivel de particulă fiind de o complexitate redusă.

Algoritm Reșantionare

For fiecare celulă C

 Calculează N_{OC} și P_{OC}

 Calculează numărul de particule re-șantionate N_{RC}

$N_{RC} = P_{OC} N_C$

 Calculează raportul dintre numărul de particule actual și cel re-șantionat

$$f_C = \frac{N_{RC}}{N_{OC}}$$

End For

For fiecare particulă p_i

 Găsește celula corespunzătoare C

If ($f_C > 1$) – numărul particulelor va crește

$F_n = \text{Int}(f_C - 1)$ Partea întreagă

$F_f = f_C - \text{Int}(f_C - 1)$ Partea fracționară

For $k=1$ to $F_n - 1$

$S.\text{Add}(p_i.\text{MakeCopy})$

End For

$r =$ valoare aleatoare între 0 și 1

If ($r < F_f$)

$S.\text{Add}(p_i.\text{MakeCopy})$

End if

End if

If ($f_C < 1$) – numărul particulelor va scădea

$r =$ valoare aleatoare între 0 și 1

If ($r > f_C$)

$S.\text{Remove}(p_i)$

End if

End if

End For

Sistemul va calcula numărul de particule ce ar trebui să existe într-o celulă după executarea procesului de reșantionare. Raportul f_C dintre acest număr și numărul de particule care există deja în celulă ne spune dacă particulele vor fi eliminate sau înmulțite. Dacă f_C este mai mare decât 1, numărul particulelor va crește. Partea întreagă a diferenței dintre f_C și 1 ne spune câte duplicări sigure vor fi efectuate pentru o particulă (de exemplu, dacă f_C este 2 fiecare particulă va fi dublată o singură dată). Partea fracționară a lui f_C este folosită pentru duplicare aleatoare: fiecare particulă va avea o probabilitate de a fi duplicată, iar această probabilitate este egală cu partea fracționară.

Dacă f_C este mai mic decât 1, numărul particulelor trebuie să scadă, iar acest lucru se obține prin eliminarea unor particule. Fiecare particulă are probabilitatea de $1 - f_C$ de a fi eliminată.

În acest punct ciclul de urmărire este complet, și algoritmul este pregătit să proceseze un nou cadru. Estimări suplimentare pentru gradul de ocupare al celulei și pentru viteză, sau gruparea celulelor în obstacole, se pot face la finalul procesului de reșantionare.




Fig. 4. Ponderare și reeșantionare [22]. Ponderarea ipotezelor de ocupare este codificată în gradul de negru al celulelor din harta din stânga.

7. Inițializarea particulelor

Procesul de măsură, ponderare și reeșantionare controlează populația de particule prin duplicare și eliminare, dar acest proces funcționează doar dacă există particule în celule pentru a putea fi înmulțite sau reduse. Pentru a putea porni acest ciclu, populația de particule trebuie inițializată.

Dintr-un punct de vedere strict probabilistic, starea fiecărei celule este necunoscută la pornirea sistemului, ceea ce înseamnă că o celulă are probabilitate egală de a fi ocupată sau liberă. În sistemul nostru de urmărire, acest lucru înseamnă că fiecărei celule ar trebui să i se atașeze un număr de particule egal cu jumătatea numărului maxim permis pe celulă. Din păcate, această abordare ar reduce mult viteza sistemului, și ar necesita o re-inițializare permanentă.

Soluția folosită se bazează pe datele de măsură ca sursă a inițializării populației de particule. Dacă o celulă de măsură este de tip obstacol și probabilitatea ei $p(m(r,c) / occupied)$ este mare, și nu există particule în celula corespunzătoare din harta urmărită, un număr mic de particule va fi creat în această celulă. Componentele de viteză inițiale v_r și v_c ale particulelor create vor fi generate în mod aleatoriu dintr-un domeniu de valori acceptabile, iar poziția inițială va fi celula în care ele sunt inițializate. În acest fel inițializarea se petrece în mod continuu, în timpul procesului de urmărire.

Particulele sunt automat eliminate atunci când se deplasează în afara hărții de ocupare urmărite, în faza de predicție. O altă cale de eliminare “administrativă”, care nu depinde de mecanismul de probabilități descris în secțiunea anterioară, este când datorită deplasării și difuziei particulelor numărul de particule într-o celulă depășește valoarea maximă permisă N_C .

8. Estimarea stării celulelor și extragerea obiectelor individuale

Rezultatul algoritmului de urmărire este populația de particule propriu zisă. Totuși, pentru testare și validare și pentru folosirea rezultatelor algoritmului în alte etape ale procesării, vom estima starea de ocupare și viteza fiecărei celule din hartă.

Probabilitatea de ocupare a fiecărei celule din hartă este aproximată prin raportul dintre numărul de particule în celulă și numărul maxim de particule permis (ecuația 1).

Componentele vectorului viteză pentru fiecare celulă sunt estimate folosind ecuația 2. Totuși, deoarece viteza unei particule nou create este complet aleatoare, aceste particule sunt excluse din procesul de estimare a vitezei. Pentru a realiza acest lucru vom folosi proprietatea de vârstă (*age*) a particulei. Vârsta unei particule este inițializată la 1 când particula este creată, și este incrementată de fiecare dată când starea particulei (poziție, viteză) este modificată prin predicție. Vârsta unei particule ne spune câte cicluri a supraviețuit particula în sistemul de urmărire.

Toate particulele dintr-o celulă care au o vârstă mai mare decât 2 sunt folosite pentru estimarea vitezei. Ele sunt numărate, și se face media componentelor de viteză pe rând și pe coloană. De asemenea, se calculează deviațiile standard ale componentelor vitezei. Dacă vitezele estimate sunt mai mici (în valoare absolută) decât dublul deviației standard corespunzătoare, celula este declarată celulă statică, deoarece viteza ei este sau prea mică, sau prea dispersată pentru a fi folosită.

Dacă se dorește identificarea obiectelor individuale din scenă, acest lucru se poate realiza prin gruparea celulelor ocupate ale hărții, pe baza criteriilor de adiacență și similaritate a vitezelor. O celulă este luată în considerare în procesul de grupare dacă probabilitatea ei de a fi ocupată este mai mare de 0.5, adică numărul de particule din ea este cel puțin $N_c/2$. Obiectele individuale sunt identificate prin algoritmul generic de etichetare a componentelor conexe. Algoritmul pornește de la o celulă ocupată și propagă în mod recursiv o etichetă celulelor vecine ocupate, până când nu mai sunt celule vecine de procesat. La terminarea etichetării unui obiect se va găsi o nouă celulă neetichetată și se va genera obiectul următor, până când nu mai există celule nevizitate.

Diferența dintre algoritmul nostru și algoritmul clasic de etichetare constă în modul în care se definește relația de vecinătate. Două celule sunt declarate vecine dacă sunt îndeplinite simultan următoarele condiții:

- Distanța dintre ele în harta de ocupare este mai mică decât 3, asta însemnând că se permite o întrerupere de o celulă.
- Diferența între orientările vectorilor viteză estimați pentru celule este mai mică de 30 de grade.
- Diferența dintre modulele vectorilor viteză estimați pentru fiecare celulă este mai mică decât 30% din valoarea modulului celui mai mare dintre cele două celule.

Procesul de etichetare este ilustrat în figura 5, panoul din mijloc, unde fiecare culoare identifică un obiect diferit. Putem observa că dacă ar fi fost folosite strict criteriile bazate pe vecinătate, obiectul în mișcare ar fi fost conectat cu structura staționară. Acest lucru nu se întâmplă deoarece folosim criteriile de asemănare pe baza informației dinamice, astfel că cele două obiecte pot fi discriminate în mod corect.




Fig. 5. Etichetarea celulelor și extragerea obiectelor[22].

Componentele conexe etichetate din celulele ocupate ale hărții sunt folosite pentru a crea obiecte 3D sub forma unor cuboide orientate, după cum se poate vedea în figura 5, panoul al treilea. Obiectele sunt grupate în două categorii, pe baza vitezei medii calculate din celulele componente: obiecte statice, desenate cu culoarea verde, și obiecte dinamice, desenate cu roșu. Orientarea se calculează doar pentru obiectele dinamice, ca orientare a vitezei medii.

9. Teste și rezultate

9.1. Evaluare calitativă

Testele calitative ne permit să evaluăm comportamentul general al sistemului în situații complexe, și sunt efectuate pe secvențe de imagini înregistrate în traficul urban real. Aceste teste arată cum harta de ocupare este calculată, cum se calculează vectorul viteză pentru fiecare celulă, și cum rezultatele la nivel de celulă sunt grupate în obiecte cuboidale având poziție, mărime, viteză și orientare. Viteza celulelor este indicată de o culoare, componenta nuanță (*hue*) arătând orientarea, iar saturația magnitudinea. Deoarece avem nevoie de o reprezentare compactă a tuturor rezultatelor din hartă, vom codifica de asemenea și probabilitatea de ocupare ca intensitatea culorii, utilizând întregul spațiu HSI.




Fig. 6. Codificarea de culoare pentru vectorii viteză (la ocupare 100% și la 50%) [22].

Cititorul poate descărca mai multe fișiere video, ce arată rezultatele în diferite situații din trafic, de la adresa: <http://users.utcluj.ro/~rdanescu/gridtrackingtests.htm>. Principalul test calitativ este arătat în secvența http://users.utcluj.ro/~rdanescu/long_sequence.avi, ce prezintă rezultatele pe o distanță semnificativă parcursă în Cluj-Napoca. Câteva momente reprezentative sunt prezentate în figura 7:

- a) Pieton care traversează, combinat cu trafic lateral și obiecte statice în depărtare.
- b) Vehicul care vine din față, obiecte statice în lateral.
- c) Două vehicule care vin din față, cel mai îndepărtat fiind vizibil doar de puțin timp.
- d) Vehicule în mișcare lângă un zid static, în timp ce noi executăm un viraj strâns la stânga.
- e) Obiect îndepărtat, urmărit cu precizie.
- f) Obiect în mișcare față de un fundal static. Protruzia din fundal din dreptul vehiculului în mișcare este un autovehicul staționar acoperit de cel în mișcare. Vehiculul nostru efectuează un viraj strâns la dreapta, ceea ce conduce la o estimare instabilă a naturii statice a fundalului în colțul dreapta sus. De asemenea, zona respectivă a fost înainte acoperită de obiectul în mișcare, ceea ce înseamnă că natura statică a celulelor nu a putut fi detectată încă, din cauza timpului scurt în care aceste celule au fost observate.
- g) Vehicul îndepărtat ce trece printre vehicule staționare. Vehiculul nostru virează la dreapta.
- h) Urmărirea unui obiect în mișcare prin coridorul îngust format de vehicule staționare.




Fig. 7. Secvență extinsă din traficul urban – momente cheie[22].

Comportamentul sistemului în caz de ocluzie este pus în evidență în secvența video <http://users.utcluj.ro/~rdanescu/cluj-occlusion.avi>. Momentele cheie sunt prezentate în figura 8. Când vehiculul nostru efectuează un viraj strâns la dreapta, un vehicul vine din partea noastră stângă și este acoperit de un vehicul care vine din dreapta. Vehiculul acoperit efectuează o manevră, schimbând orientarea spre stânga lui. În timpul ocluziei, particulele obiectului acoperit devin difuze, indicând incertitudinea asupra traiectoriei vehiculului, iar direcția corectă este identificată în mod corect atunci când obiectul devine din nou vizibil.




Fig. 8. Ocluzie dinamică[22].

O secvență lungă, înregistrată în timp ce vehiculul nostru este oprit într-o intersecție, a produs rezultatele prezentate în fișierul video <http://users.utcluj.ro/~rdanescu/wob-occlusion.avi>. Un moment esențial al secvenței este prezentat în figura 9: un vehicul vine din stânga noastră, face un viraj la dreapta și apoi se îndepărtează, ieșind din scenă. În timpul acestei manevre el acoperă obiectul static din stânga lui, dar nu se confundă cu acesta datorită algoritmului de grupare, care ține cont de viteze. Observăm cum valorile de ocupare devin difuze în timp ce obiectul este acoperit de un camion mare, care apoi acoperă și obiectele statice din dreapta.




Fig. 9. Viraj lângă un obiect staționar, cu ocluzie [22].

9.2. Evaluare numerică în medii controlate

Evaluarea numerică a fost efectuată pe secvențe achiziționate în scenarii controlate, cu viteza și orientarea obiectului urmărit cunoscute. Au fost efectuate patru teste, cu aceeași orientare (45 grade) dar viteze diferite: 30 km/h, 40 km/h, 50 km/h, 60 km/h. Rezultatele evaluate au fost viteza și orientarea cuboidului 3D obținut prin gruparea celulelor ocupate. Aceste rezultate sunt comparate cu valorile reale, dar sunt comparate și cu un alt algoritm de extragere a informației 3D dinamice, bazat pe flux optic (optical flow) combinat cu stereoviziune. Acest algoritm poate furniza viteză și orientare pentru obiectele 3D obținute prin gruparea punctelor 3D având, în mod suplimentar, și informație de viteză [21]. Secvențele de test sunt foarte favorabile abordării de tip flux optic, deoarece vehiculul țintă este foarte bine vizibil, are multe trăsături care se pot corela între cadre succesive, ceea ce duce la posibilitatea de a avea mulți vectori viteză pentru punctele 3D, și deci la o viteză bună a cuboidului.

Rezultatele estimării vitezei și a orientării sunt prezentate în graficele din figurile 11 ... 14. Rezultatele metodei bazate pe harta de ocupare sunt afișate cu linie roșie, iar cele ale metodei bazate pe flux optic cu line albastră. Putem observa că ambele metode converg rapid către valorile adevărate, dar metoda hărții de ocupare este mai stabilă (deviația standard a erorilor este mai mică) și mai precisă (eroare medie absolută mai mică). Aceste concluzii sunt susținute și de tabelele I și II.

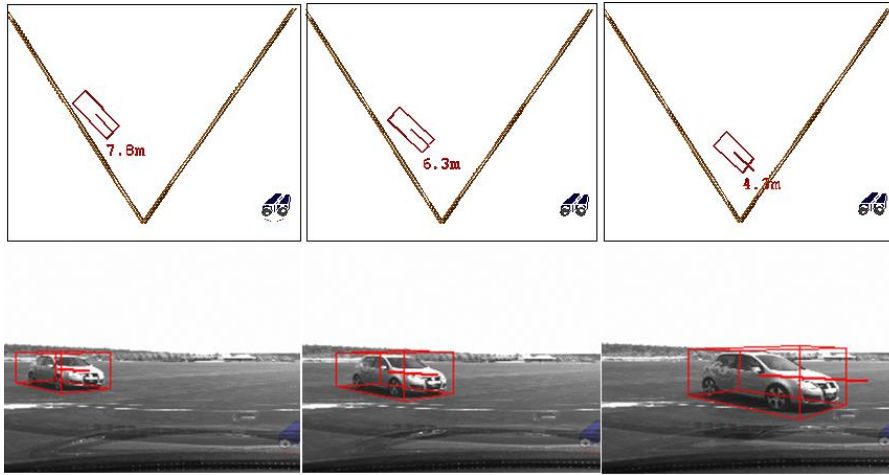


Fig. 10. Secvența de test preluată în condiții controlate [22].




Fig. 11. Estimarea vitezei și a orientării, testul la 30 km/h [22].




Fig. 12. Estimarea vitezei și a orientării, testul la 40 km/h[22].




Fig. 13. Estimarea vitezei și a orientării, testul la 50 km/h[22].




Fig. 14. Estimarea vitezei și a orientării, testul la 60 km/h[22].

TABEL 1
REZULTATE NUMERICE – ACURATEȚEA ESTIMĂRII VITEZEI

Viteza țintei	MAE Hartă de ocupare	STDEV Hartă de ocupare	MAE flux optic	STDEV Flux optic
30 km/h	0.9016	0.9731	2.0141	2.3087
40 km/h	1.0184	0.9730	2.1181	1.9017
50 km/h	2.4989	2.3370	3.7329	4.4966
60 km/h	2.1279	1.3858	3.0677	2.2725

TABEL 2
REZULTATE NUMERICE – ACURATEȚEA ESTIMĂRII ORIENTĂRII

Viteza țintei	MAE Hartă de ocupare	STDEV Hartă de ocupare	MAE flux optic	STDEV Flux optic
30 km/h	0.9728	0.8376	1.8219	2.0122
40 km/h	1.0321	0.8616	1.1962	1.0146
50 km/h	0.4695	0.2659	1.2775	1.1095
60 km/h	0.9343	0.6739	1.4554	1.1634

Performanța de timp depinde de cantitatea de obstacole din scenă, care influențează numărul total de particule. Pentru o scenă urbană tipică, și pentru un număr total de particule acceptate pentru o celulă $N_C=50$, timpul total de rulare este de 40 ms pe cadru, pe un procesor Intel Core 2 Duo la 2.1 GHz. Acest algoritm a rulat în sistemul complex de percepție a mediului pe bază de stereoviziune SCABOR (Stereo Camera-Based Object Recognition), unde au fost integrați și algoritmi de detecție a benzilor de circulație, clasificarea obiectelor, etc, și astfel rata de procesare la bordul autovehiculului a fost coborâtă la 10 cadre pe secundă.

10. Concluzii și perspective

Acest capitol prezintă o soluție pentru modelarea și urmărirea mediului din traficul auto, soluție ce folosește conceptul de particulă pentru estimarea ocupării și a vitezei celulelor unei hărți de ocupare. Această metodă flexibilă și rapidă este capabilă să urmărească în mod corect mediul dinamic chiar și la viteze relative mari, fără a necesita o rată mare de achiziție sau de reconstrucție stereo. Secvențele pe care a fost testat sistemul au arătat că acesta este suficient

de fin pentru a detecta și a măsura viteza unui pieton, dar și pentru măsurarea vitezei unui vehicul rapid. Acuratețea de estimare a vitezelor și a orientărilor este dovedită de testele efectuate în situații controlate.

Soluția de urmărire pe bază de hartă de ocupare cu particule este o extensie elegantă a soluțiilor de urmărire studiate și prezentate în secțiunea introductivă. Abordarea bazată pe populația de particule eliberează proiectantul algoritmului de găsirea unei soluții pentru distribuția probabilităților vitezelor într-o celulă, și poate aborda mai multe ipoteze de viteză, chiar dacă ele sunt divergente. De asemenea, nu este necesară estimarea distribuției vitezelor, iar procesul de măsură controlează doar crearea sau eliminarea particulelor. Metoda propusă este o nouă privire asupra problemei hărților de ocupare, o vedere orientată spre implementarea practică, și care poate duce la alte extensii interesante.

Metoda prezentată nu este o înlocuire a urmăririi obiectelor pe bază de model, ci o metodă pentru reprezentarea și procesarea intermediară a datelor senzoriale. Probabilitatea de ocupare și parametrii dinamici ai fiecărei celule pot sta la baza altor algoritmi, precum gruparea perceptuală a trăsăturilor, urmărirea pe bază de model cuboidal, sau chiar fuzionarea mai multor surse de informație senzorială.

Avantajele create de o reprezentare intermediară de calitate sunt vizibile prin rezultatele reconstrucției obiectelor din celulele hărții urmărite. Calitatea rezultatelor hărții de ocupare ca bază pentru reconstrucția și urmărirea obiectelor discrete se poate vedea și din comparația cu o altă metodă populară de reprezentare intermediară în viziunea computerizată, punctele 3D cu vectori de viteză atașați, vectori obținuți prin utilizarea metodei Lucas-Kanade de calcul a fluxului optic.

Metoda descrisă lasă suficiente oportunități pentru dezvoltare ulterioară. De exemplu, multe din calculele efectuate de algoritm se pot paraleliza, pentru creșterea vitezei de calcul. Calculele la nivel de particule, precum precizarea noii poziții, se pot paraleliza masiv, pe când calculele legate de celule se pot paraleliza la nivel de regiune.

Probabil că cea mai importantă extensie va fi utilizarea capacității particulelor de a stoca informație suplimentară. De exemplu, vârsta particulei ar putea fi folosită pentru mai mult decât validarea vitezei. Vârsta s-ar putea utiliza la ajustarea varianței ce controlează extragerea aleatoare a variațiilor aplicate vitezei și poziției particulelor în faza de predicție – dacă particula este mai veche, elementele aleatorii pot fi scăzute. Particulele pot fi etichetate cu un identificator unic, care ne-ar permite să reconstituim traiectoria unui obiect. De asemenea, se pot adăuga parametri precum înălțimea sau clasa obiectului din care face parte particula, pentru a putea fi integrate în mecanismul de urmărire sau în aplicațiile ce utilizează rezultatul hărții estimate.

11. Bibliografie

[1] U. Franke, C. Rabe, H. Badino, and S. Gehrig, "6d-vision: Fusion of stereo and motion for robust environment perception," in proc of 27th Annual Meeting of the German Association for Pattern Recognition DAGM '05, Vienna, October, 2005, pp. 216-223.

[2] D. Pfeiffer, U. Franke, "Efficient Representation of Traffic Scenes by Means of Dynamic Stixels", in proc of IEEE Intelligent Vehicles Symposium (IEEE-IV), 2010, pp. 217-224.

[3] S. Cherng, C. Y. Fang, C. P. Chen, S. W. Chen, "Critical Motion Detection of Nearby

- Moving Vehicles in a Vision-Based Driver-Assistance System”, IEEE Transactions on Intelligent Transportation Systems, Vol. 10, No. 1, March 2009, pp. 70-82.
- [4] A. Elfes, “A Sonar-Based Mapping and Navigation System”, in proc of IEEE International Conference on Robotics and Automation, April 1986, pp. 1151-1156.
- [5] A. Elfes, “Using Occupancy Grids for Mobile Robot Perception and Navigation”, Computer, vol. 22, No. 6, June 1989, pp. 46-57.
- [6] C. Coue, C. Pradalier, C. Laugier, T. Fraichard, P. Bessiere, “Bayesian Occupancy Filtering for Multitarget Tracking: An Automotive Application”, The International Journal of Robotics Research, Vol 25, No 1, 2006, pp. 19-30.
- [7] C. Chen, C. Tay, K. Mekhnacha, C. Laugier, “Dynamic environment modeling with gridmap: a multiple-object tracking application”, in proc of International Conference on Automation, Robotics and Computer Vision (ICARCV) 2006, pp. 1-6.
- [8] T. Weiss, B. Schiele, K. Dietmayer, “Robust Driving Path Detection in Urban and Highway Scenarios Using a Laser Scanner and Online Occupancy Grids”, in proc of IEEE Intelligent Vehicles Symposium 2007, pp. 184-189.
- [9] S. Pietzch, T. D. Vu, J. Burtlet, O. Aycard, T. Hackbarth, N. Appenrodt, J. Dickmann, B. Radig, "Results of a Precrash Application based on Laser Scanner and Short Range Radars", IEEE Transactions on Intelligent Transportation Systems, Vol. 10, No. 4, 2009, pp. 584-593.
- [10] T. Gindele, S. Brechtel, J. Schroeder, R. Dillmann, “Bayesian Occupancy Grid Filter for Dynamic Environments Using Prior Map Knowledge”, in proc of IEEE Intelligent Vehicles Symposium 2009, pp. 669 - 676
- [11] S. Thrun, "Learning Occupancy Grids With Forward Sensor Models", Autonomous Robots, Vol. 15, No 2, 2003, pp. 111-127.
- [12] H. Badino, U. Franke, R. Mester, “Free Space Computation Using Stochastic Occupancy Grids and Dynamic Programming”, Workshop on Dynamical Vision, ICCV, 2007, pp. 1-12.
- [13] M. S. Darms, P. E. Rybski, C. Baker, C. Urmson, “Obstacle Detection and Tracking for the Urban Challenge”, IEEE Transactions on Intelligent Transportation Systems, Vol. 10, No. 3, September 2009, pp. 475-485.
- [14] C. Brailon, K. Usher, C. Pradalier, J. Crowley, C. Laugier, “Fusion of stereo and optical flow data using occupancy grids”, in proc of IEEE International Conference on Intelligent Transportation Systems, 2006, pp. 1240-1245.
- [15] J. Y. Chen, J. Hu, “Probabilistic Map Building by Coordinated Mobile Sensors”, in proc of IEEE International Conference on Networking, Sensing and Control, 2006, pp. 807-812.
- [16] M. Isard, A. Blake, “CONDENSATION -- conditional density propagation for visual tracking”, International Journal of Computer Vision, Vol. 29, No. 1, 1998, pp. 5-28.
- [17] F. Oniga, S. Nedevschi, “Processing Dense Stereo Data Using Elevation Maps: Road Surface, Traffic Isle, and Obstacle Detection”, IEEE Transactions on Vehicular Technology, Vol. 59, No. 3, March 2010, pp. 1172-1182.
- [18] I. Haller, C. Pantilie, F. Oniga, S. Nedevschi, “Real-time semi-global dense stereo solution with improved sub-pixel accuracy”, in proc of IEEE Intelligent Vehicles Symposium 2010 (IV 2010), pp. 369-376.
- [19] W. van der Mark, D. M. Gavrila, “Real-Time Dense Stereo for Intelligent Vehicles”, IEEE Transactions on Intelligent Transportation Systems, Vol. 7, No. 1, March 2006, pp. 38-50.
- [20] A. Rosenfeld, J. L. Pfaltz, “Sequential Operations in Digital Picture Processing”, Journal of the Association for Computing Machinery, Vol. 13, No. 4, October 1966, pp. 471-494.
- [21] C. Pantilie, S. Nedevschi, “Real-time Obstacle Detection in Complex Scenarios Using Dense Stereo Vision and Optical Flow”, IEEE Conference on Intelligent Transportation Systems (IEEE-ITSC), 2010, pp. 439-444.

[22] R. Danescu, F. Oniga, S. Nedevschi, “Modeling and Tracking the Driving Environment with a Particle Based Occupancy Grid”, IEEE Transactions on Intelligent Transportation Systems, vol. 12, no. 4, 2011, pp. 1331-1342.

V. Utilizarea particulelor pentru urmărirea hărților dinamice de înălțimi

1. Introducere

Scenele de trafic sunt medii 3D complexe, cu multe obiecte relevante, care uneori sunt dificil de modelat prin paralelipipedul orientat (cuboidul) clasic. Multe obiecte nu se pot aproxima ușor ca cuboide și uneori e nevoie de o descriere mai detaliată a formei obiectului [1], sau ele nu sunt complet observabile pentru a se putea defini clar ca un cuboid, iar problemele de asociere a măsurătorilor specifice urmăririi pe bază de model cuboidal nu sunt pot fi rezolvate [2].

Obiectele relevante din trafic sunt de multiple feluri: autovehicule, pietoni, biciclete, refugii mediane, tufișuri, borduri și multe altele. Unele obiecte sunt statice, altele sunt dinamice, sau pot alterna starea dintre static și dinamic. Din aceste motive, mulți cercetători au încercat să găsească reprezentări generale, care să nu fie dependente de natura sau de forma obiectului. O astfel de soluție este de a păstra punctele 3D furnizate de senzori și a le utiliza direct în aplicații de evitare a obstacolelor sau de creare a hărților și de orientare, asta dacă aceste puncte sunt suficient de precise, precum cele furnizate de senzori de tip laser [3]. 6D vision [4] este o abordare ambițioasă de a modela mediul ca o mulțime de puncte 3D, fiecare punct având propriul lui vector viteză. O abordare ceva mai compactă este stixelul dinamic [5], ce modelează părțile vizibile ale obstacolelor ca o mulțime de structuri verticale înguste.

Hărțile digitale de înălțimi (Digital Elevation Maps, DEM) sunt o soluție simplă dar valoroasă pentru modelarea mediilor 3D complexe. Mediul este reprezentat ca o hartă 2D, fiecare celulă din această hartă (vedere de sus a mediului) fiind caracterizată de o înălțime. Hărțile acestea de înălțimi pot fi structuri mari de date, folosite pentru descrierea formelor de relief [6], ceea ce le face utile pentru explorarea robotică a planetelor [7], dar pot fi și structuri locale de dimensiuni mai mici, folosite pentru navigația robotică [8], pentru reprezentarea mediului în aplicații de asistență a conducerii auto [9], sau chiar pentru urmărirea pietonilor în medii interioare [10]. Hărțile digitale de înălțime pot fi construite în timp real, folosind mai multe tipuri de senzori 3D, cele mai populare fiind cele bazate pe laser [2] sau pe stereoviziune [9] [10]. Celulele hărții de înălțimi pot fi apoi analizate și clasificate în zone traversabile, zone de tip obstacol, sau altele [8] [9].

Reprezentarea mediului sub forma hărților de înălțimi este uneori descrisă ca o reprezentare în 2.5 dimensiuni [11], deoarece descrierea nu este completă – podurile sau tunelurile, de exemplu, nu pot fi reprezentate corect. Din aceste motive, cercetătorii au propus mai multe extensii. Una dintre problemele hărților de înălțimi, descrisă în [11], este că dacă pentru înălțimea unei celule se ia media sau maximul înălțimii punctelor senzoriale din celula respectivă, podurile sau tunelurile vor apărea ca fiind netraversabile. Presupunând că structurile aeriene nu sunt importante, acești cercetători propun un algoritm optimizat, care identifică golurile din structurile verticale și generează harta pentru suprafețele traversabile mai joase. În [12] este prezentată o altă extensie a hărții de înălțimi, numită Hartă de Suprafețe Multinivel (Multi Level Surface Map), care poate modela cu succes structurile suspendate. Mediul este organizat ca o hartă în două dimensiuni, care în loc să stocheze în fiecare celulă o înălțime va

stoca o mulțime de elemente de suprafață, modelate ca distribuții Gaussiene de înălțime și adâncime. Astfel, zona de sub un pod va fi un element de suprafață, iar podul alt element. Înălțimile sunt definite de o medie și o deviație standard, care sunt actualizate printr-un mecanism probabilistic.

O extensie chiar mai generală este prezentată în [13]: harta de ocupare multi-volum, o reprezentare probabilistică a volumelor de înălțime pentru fiecare celulă din hartă, fiecare volum având o poziție de început și o înălțime, iar volumele pot fi ocupate sau goale. Ocuparea unui volum este modelată probabilistic, astfel încât se pot modela volume ocupate și libere, dar și gradul de incertitudine asupra acestor proprietăți.

O altă clasă de soluții pentru modelarea și percepția mediilor 3D generice ca hărți bidimensionale văzute de sus este cea bazată pe hărți de ocupare. Similare cu hărțile de înălțime, hărțile de ocupare sunt bazate tot pe celule discrete, dar care păstrează, în loc de înălțime, probabilitatea ca celula să fie ocupată sau liberă. Pentru unele aplicații robotice de timp real această reprezentare este mult mai utilă. Datorită simplității lor, și pentru că pot fi adaptate să funcționeze cu o largă varietate de senzori, hărțile de ocupare sunt implicate în multiple contribuții științifice, și multe tehnici sofisticate pentru urmărirea lor au fost concepute.

Elfes a descris una dintre primele aplicații ale hărților de ocupare, în contextul navigației robotice bazate pe sonar [14]. Adăugarea informației de viteză la reprezentarea bazată pe ocupație crește complexitatea raționamentului probabilistic, pentru că celulele hărții devin dependente una de alta. Rezultatele lui Coue și a asociaților lui, prezentate în [2], se bazează pe utilizarea unei hărți 4D, unde vitezele devin cele două dimensiuni suplimentare, iar estimarea vitezei devine estimarea ocupării celulei având coordonatele vitezei respective. O altă soluție pentru reprezentarea vitezei este prezentată de Chen în [15]. În loc de hartă cu dimensiuni suplimentare, fiecare celulă are o distribuție de viteze sub forma unei histogramme. Mecanismul de inferență Bayesiană se bazează pe datele senzoriale și pe celule anterioare, lista antecedentilor fiind decisă de vitezele din histogramă.

Unele soluții bazate pe harta de ocupare abordează separat zonele dinamice din mediu față de zonele statice. În [16], teoria Dempster-Shafer a evidenței este folosită pentru a actualiza o hartă de ocupare din date de măsură laser, iar zonele obiectelor în mișcare sunt identificate ca zone care intră în conflict cu evidența și au incertitudine mare. O abordare similară, dar care folosește stereoviziunea în locul laserului este prezentată în [17]. Regiunile de tip obstacol, identificate prin incertitudinile evidențelor, sunt grupate și urmărite prin modelul cuboidal, ca obiecte dinamice, în afara hărții de ocupare. O metodă care calculează harta de ocupare direct în spațiul de disparități al stereoviziunii este prezentată în [18], și se bazează pe paralelizarea GPU pentru performanță în timp real.

O combinație între harta de înălțimi și harta de ocupare probabilistică pare să fie o extensie naturală a ambelor metode de modelare a mediului. În [19] găsim o soluție bazată pe stereoviziune care menține două hărți, una pentru ocupare și una pentru înălțime, iar în [20] harta de înălțimi este doar un proces intermediar pentru obținerea reprezentării de tip hartă de ocupare.

În acest capitol vom descrie o soluție probabilistică pentru modelarea și urmărirea mediului 3D dinamic, ce combină capabilitățile hărții de înălțimi pentru reprezentarea statică a mediului cu puterea hărții de ocupare dinamice pentru reprezentarea obstacolelor statice și dinamice. Dacă

articole precum [12] și [13] folosesc metode sofisticate pentru modelarea mediilor 3D statice, iar soluțiile precum cele descrise în [19] și [20] folosesc hărțile de ocupare împreună cu cele de înălțimi, metoda descrisă în acest capitol este proiectată să modeleze și să urmărească hărți de înălțimi complet dinamice. Toate celulele din hartă, statice sau dinamice, ocupate sau libere, sunt actualizate folosind același mecanism de inferență, iar rezultatele urmăririi pot fi automat convertite în hărți statice de înălțimi sau în hărți de ocupare dinamică.

Această metodă unificată de modelare și urmărire este bazată pe particule, care nu sunt doar ipoteze ale unei stări, ci și elementele constructive ale modelului lumii. Particulele se pot deplasa dintr-o celulă în alta, oferind un mecanism elegant și intuitiv pentru predicție, și pot fi create sau distruse pe baza potrivirii dintre ele și măsurători, în faza de actualizare a stării. În capitolul precedent am descris o astfel de metodă aplicată pentru hărțile de ocupare dinamice, metodă care a fost publicată și în [21], și descrisă în capitolul IV al acestei cărți. Am introdus conceptul de particulă în mișcare, particula fiind o unitate de ocupare a unei celule, care poate purta și informație de viteză. Încă de atunci am înțeles că particula poate purta mai multă informație decât viteza, iar o astfel de informație suplimentară este înălțimea celulei. O populație de particule cu viteză și înălțime devine un model probabilistic pentru o hartă de înălțimi complet dinamică.

În continuarea acestui capitol vor fi prezentate detaliile metodei care transformă conceptul într-o soluție funcțională: predicția pe bază de particule în mișcare, abordarea variațiilor discontinue în înălțimile măsurate datorate unghiului propriu de aplecare, integrarea modelului de măsură prin stereoviziune în procesul de ponderare a particulelor, și procesul de reșantionare care reduce populația de particule când acestea nu se potrivesc cu măsurătoarea. Datele de măsură sunt formate dintr-o hartă de înălțimi statică, instantanee, creată din punctele dense obținute prin stereoviziune și procesate conform metodei descrise în [9].

Noul model al lumii și noua metodă de urmărire bazată pe acesta au fost evaluate pentru acuratețe și robustețe în descrierea aspectelor dinamice și statice ale mediului de trafic. Au fost utilizate secvențe cu date 3D laser de înaltă acuratețe pe post de date etalon, și au fost calculate metrici standard pentru estimarea acurateții estimărilor 3D dense, precum procentul înălțimilor eronate estimate sau erorile pătratice medii. Față de harta inițială instantanee, urmărirea a îmbunătățit considerabil acuratețea percepției 3D a scenei, dar și densitatea de estimare, numărul de celule din hartă cu o estimare de înălțime validă. De asemenea, sistemul este capabil să estimeze corect viteza vehiculelor în mișcare.

Metoda de urmărire a hărților dinamice folosind particulele este o contribuție originală a autorului, și a fost publicată în articolul de jurnal [31] și articolul de conferință [32]. Unele figuri din acest capitol sunt preluate din aceste articole.

2. Harta de înălțimi dinamică bazată pe particule

O reprezentare de tip hartă de înălțimi a unei scene 3D în sistemul de coordonate XYZ (vom lua în considerare un sistem de coordonate cu originea pe șosea în fața autovehiculului, axa X orientată în față, axa Y spre stânga și axa Z în sus) este o funcție $Z(X,Y)$, care atașează fiecărui punct (X,Y) din planul orizontal XOY o coordonată de înălțime Z . Această funcție continuă poate fi apoi aproximată prin împărțirea unei regiuni finite din planul XOY în celule, fiecare celulă i fiind identificată prin poziția ei într-o matrice finită, poziție descrisă de rândul r_i și coloana c_i . Pentru fiecare celulă se atașează o înălțime h_i , și astfel harta de înălțimi devine un tablou de valori de înălțimi.




Fig. 1. a) Harta dinamică de înălțimi, o suprafață 3D cu vectori de viteză atașați; b) suprafața continuă este aproximată printr-o grilă de celule de dimensiune fixă, cu înălțimi și viteze pentru fiecare celulă [31].

Dacă scena 3D este dinamică, fiecare celulă din harta discretă de înălțimi va avea atașată și o viteză. Dacă aplicația este limitată la scenariul conducerii auto, se poate presupune că obiectele din scenă se deplasează în principal în planul orizontal, iar vectorul viteză are doar două componente, v^x and v^y . În consecință, în cazul continuu vom avea două funcții, $v^x(X,Y)$ and $v^y(X,Y)$, iar în cazul discret vom avea două tablouri de viteze, v^r_i and v^c_i – viteza rând și viteza coloană pentru fiecare celulă i din hartă, după cum se arată în figura 1.

Astfel, harta digitală de înălțimi poate fi descrisă de trei tablouri de valori, h_i , v^r_i and v^c_i . În cazul ideal, toate aceste valori pot fi măsurate, și o descriere precisă a lumii poate fi generată. În realitate, senzorii au o rază de acțiune limitată, o precizie limitată, o fiabilitate limitată, și toate aceste probleme fac ca unele celule din hartă să devină neobservabile, sau să aibă o măsurătoare greșită. Aceste limitări cauzează incertitudini, iar aceste incertitudini trebuie să fie înglobate în modelul lumii. Astfel, în loc să calculăm valori unice pentru viteze și înălțimi, vom calcula densități de probabilitate. O celulă i din harta dinamică de înălțimi va avea asociată o variabilă aleatoare $\mathbf{X}_i = (h_i, v^r_i, v^c_i)^T$, cu trei dimensiuni (înălțime, viteză pe coordonata rând, și viteză pe coordonata coloană). Obiectivul algoritmului de urmărire este de a calcula densitatea de probabilitate a lui \mathbf{X}_i , pentru fiecare celulă i din hartă, pe baza unei secvențe de măsurători $\mathbf{Z}(0) \dots \mathbf{Z}(t)$. Măsurătoarea \mathbf{Z} include toată informația senzorială disponibilă la momentul de timp t , pentru toată harta, nu doar cea limitată la celula curentă.

$$p(\mathbf{X}_i(t) | \mathbf{Z}(0), \mathbf{Z}(1), \dots, \mathbf{Z}(t)) \propto p(\mathbf{Z}(t) | \mathbf{X}_i(t))p(\mathbf{X}_i(t) | \mathbf{Z}(0), \dots, \mathbf{Z}(t-1)) \quad (1)$$

Problema urmăririi este formulată ca o problemă de estimare recursivă Bayesiană a densităților de probabilitate, descrisă de ecuația (1). Densitatea din trecut a stării $p(\mathbf{X}_i(t-1) | \mathbf{Z}(0), \dots, \mathbf{Z}(t-1))$ și modelul de tranziție a stărilor $p(\mathbf{X}_i(t) | \mathbf{X}_i(t-1))$ se combină pentru a forma densitatea de probabilitate a stării prezente $p(\mathbf{X}_i(t) | \mathbf{Z}(0), \dots, \mathbf{Z}(t-1))$, iar informația senzorială la timpul prezent t este utilizată pentru a actualiza starea prin modelul de observație $p(\mathbf{Z}(t) | \mathbf{X}_i(t))$.

Presupunând că doar trecutul imediat contează (presupunerea unui model Markov de ordinul 1), predicția pentru o celulă i se poate calcula din estimarea trecută a stărilor pentru fiecare celulă j din hartă, $p(\mathbf{X}_i(t-1) | \mathbf{Z}(0), \dots, \mathbf{Z}(t-1))$, și modelul dinamic $p(\mathbf{X}_i(t) | \mathbf{X}_j(t-1))$.

$$p(\mathbf{X}_i(t) | \mathbf{Z}(0), \dots, \mathbf{Z}(t-1)) = \sum_j p(\mathbf{X}_i(t) | \mathbf{X}_j(t-1))p(\mathbf{X}_j(t-1) | \mathbf{Z}(0), \dots, \mathbf{Z}(t-1)) \quad (2)$$

Cele mai folosite tehnici pentru aproximarea densităților de probabilitate în aplicații de urmărire sunt aproximarea prin funcție Gaussiană, folosită în principal în filtrul Kalman, și aproximarea prin eșantioane discrete, folosită în urmărirea bazată pe particule. O descriere comparativă a celor mai populare soluții pentru reprezentarea funcțiilor de densitate de probabilitate se găsește în [22]. Metodele bazate pe particule sunt preferate atunci când funcția de densitate (PDF) este multi-modală (are mai multe maxime), sau când forma ei nu este cunoscută. Un alt motiv pentru care soluția noastră este bazată pe particule este că pe baza particulelor se poate defini un mecanism simplu și intuitiv pentru mutarea lor dintr-o celulă în alta.

Harta dinamică de înălțimi se va defini, la un anumit timp t , printr-o mulțime de particule $S(t)$, iar fiecare particulă k a acestei mulțimi este definită de un vector de stare $\mathbf{x}_k(t)$:

$$S(t) = \{\mathbf{x}_1(t), \mathbf{x}_2(t), \dots, \mathbf{x}_{N_S(t)}(t)\},$$

$$\mathbf{x}_k(t) = ({}_p c_k(t), {}_p r_k(t), {}_p h_k(t), {}_p v_k^c(t), {}_p v_k^r(t))^T \quad (3)$$

Fiecare particulă k este localizată într-o celulă definită de un rând ${}_p r_k$, și o coloană ${}_p c_k$. Harta are 250 de rânduri și 120 de coloane, iar fiecare celulă este un pătrat cu latura de 20 cm. Astfel, harta acoperă o suprafață de 50x24 metri în planul orizontal (XOY). Fiecare particulă reprezintă o ipoteză asupra stării celulei: o posibilă înălțime ${}_p h_k(t)$, o posibilă viteză longitudinală ${}_p v_k^r(t)$ și o posibilă viteză laterală ${}_p v_k^c(t)$, după cum este ilustrat în figura 2.




Fig. 2. Harta de înălțimi bazată pe particule [31]. Fiecare celulă are o populație de particule, iar fiecare particulă are înălțime și viteză. Populația de particule poate aproxima o densitate de probabilitate multi-modală a înălțimilor și a vitezelor pentru fiecare celulă din hartă.

Viteza și poziția pe rând și pe coloană a particulelor sunt exprimate în unități celulă, multipli ai dimensiunii laturii celulei ($D_X = D_Y = 20$ cm), iar înălțimea este exprimată ca multipli ai unității de înălțime ($D_H=1$ cm).

Pe baza mulțimii de particule $S(t)$, se pot aproxima densitățile de probabilitate implicate în procesul de urmărire. Densitatea de probabilitate multi-modală a stării unei celule este dată de particulele a căror poziție, dată de p_{Ck} și p_{rk} , coincide cu rândul și coloana celulei i , i , r_i și c_i .

Modelul dinamic este descris de ecuația (4). Presupunând că starea anterioară a unei celule j este descrisă de valoarea vectorului de stare al unei particule, $\mathbf{x}_k(t-1)$, starea curentă poate fi descrisă de un eșantion extras din distribuția normală de probabilitate centrată în $\mathbf{f}(\mathbf{x}_k(t-1))$ și având matricea de covarianță $\mathbf{Q}_i(t)$. Funcția \mathbf{f} codifică modelul de mișcare uniform al unei particule, precum și translația și rotația platformei de observație (a vehiculului nostru), iar matricea de covarianță codifică posibilele diferențe dintre modelele presupuse și lumea reală. Ecuațiile modelului de mișcare folosite pentru predicția stării sunt descrise în secțiunea 4.

$$p(\mathbf{X}_i(t) | \mathbf{X}_j(t-1) = \mathbf{x}_k(t-1)) \approx N(\mathbf{f}(\mathbf{x}_k(t-1)), \mathbf{Q}_i(t)) \quad (4)$$

Predicția în cazul general, descrisă de ecuația (2), bazată pe starea anterioară și pe modelul dinamic, ia forma concretă a modificării poziției și a vitezei particulelor, prin aplicarea modelului de mișcare descris de funcția \mathbf{f} (deplasamentul determinist al particulelor) și adăugarea elementului aleator controlat de matricea $\mathbf{Q}_i(t)$, prin care se realizează difuzia stohastică.

Modelul de măsură $p(\mathbf{Z}(t) | \mathbf{X}_i(t) = \mathbf{x}_k(t))$ este definit pentru fiecare celulă i , și descrie densitatea de probabilitate a măsurătorii $\mathbf{Z}(t)$ condiționată de presupunerea că starea reală a celulei este cea descrisă de particula k . Vom presupune că această densitate este o densitate normală (Gaussiană) centrată în $(r_i, c_i, p, h_k(t))$, având o matrice de covarianță a erorilor $\mathbf{\Sigma}_i(t)$, care descrie incertitudinea senzorului:

$$p(\mathbf{Z}(t) | \mathbf{X}_i(t) = \mathbf{x}_k(t)) \approx N((r_i, c_i, p, h_k(t))^T, \mathbf{\Sigma}_i(t)) \quad (5)$$

Actualizarea stării, descrisă pentru cazul general de ecuația (1), ia forma asocierii, pentru fiecare particulă, a unei ponderi proporțională cu gradul de potrivire între particulă și măsurătoare. Ponderea nu este inclusă în modelul lumii descris anterior, deoarece imediat ce particulele sunt ponderate ele sunt re-eșantionate [23], iar acest proces va genera o nouă populație de particule cu ponderi egale.

3. Vedere de ansamblu asupra soluției

Scopul algoritmului de urmărire a hărții dinamice de înălțimi este de a estima în mod continuu densitatea de probabilitate pentru înălțimile și vitezele fiecărei celule din hartă. Deoarece aceste densități de probabilitate sunt reprezentate de particule, scopul algoritmului este de a actualiza în mod continuu populația de particule a scenei, un proces controlat de datele de măsură.

O diagramă bloc a algoritmului este prezentată în figura 3.

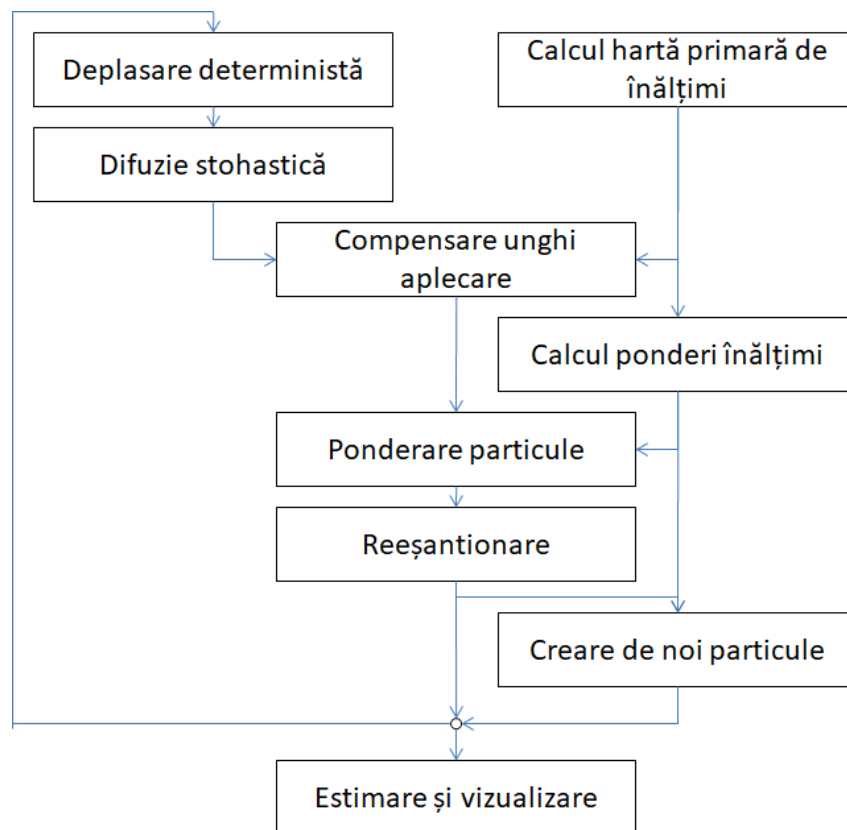


Fig. 3. Algoritm de urmărire a hărților dinamice de înălțimi, vedere de ansamblu.

În continuare vom descrie pe scurt fiecare bloc de procesare din figura 3. O descriere detaliată a celor mai importante blocuri va fi oferită în secțiunile următoare. Pașii principali ai algoritmului urmează mecanismul de deplasare-difuzie-ponderare-reeșantionare a variantei de filtru de particule numit CONDENSATION, prezentat în lucrarea [23].

Primul pas al ciclului de urmărire este *Deplasarea Particulelor*, un proces care preia populația de particule rezultată din ciclul anterior de urmărire și aplică ecuațiile de mișcare ale vehiculului observator și ale particulelor pentru a prezice pozițiile lor prezente. Particulele sunt deplasate de la o celulă la alta datorită celor două mișcări componente.

După deplasare, particulele sunt supuse procesului de *Difuzie stohastică*. Stările particulelor (poziție, înălțime și viteză) sunt modificate prin cantități aleatoare, care reflectă incertitudinile care afectează evoluția scenei în timp (sau diferența dintre modul real în care evoluează scena și felul în care prezicem noi evoluția aceasta în timp prin modelul de mișcare). Deplasarea și difuzia formează predicția, care pregătește populația de particule să întâlnească măsurătoarea și să fie actualizată de aceasta. Detaliile procesului de predicție sunt prezentate în secțiunea 4.1.

Măsurătoarea este disponibilă sub forma unei hărți de înălțimi primare, o hartă statică de aceeași dimensiune ca cea urmărită, calculată direct prin procesarea informației stereo dense. Această hartă primară este afectată de erorile specifice sensorului, care trebuie luate în considerare. Mai multe detalii despre această hartă sunt prezentate în secțiunea 4.2.

Primul contact dintre particule și datele de măsură este procesul de *Compensare a Unghiului de Aplecare*. Acest unghi se poate schimba abrupt, într-un mod imprevizibil, datorită imperfecțiunilor de pe suprafața drumului, sau datorită manevrelor bruște. Schimbarea acestui

unghi afectează înălțimea celulelor din hartă în mod semnificativ, și pentru ca acest lucru să nu afecteze procesul de urmărire sistemul trebuie să estimeze diferența de aplecare dintre cadre, și să ajusteze înălțimea particulelor la noul unghi. Această metodă va fi descrisă în secțiunea 4.3.

După ajustarea înălțimilor bazată pe unghiul de aplecare, particulele sunt supuse procesului de *Ponderare*. Acest proces va atașa fiecărei particule o pondere care reflectă calitatea potrivirii dintre înălțimea particulei dintr-o celulă anume și înălțimile din harta primară. Acest proces trebuie să ia în considerare incertitudinile specifice stereoviziunii, codificate în modelul de observație. Pentru accelerarea calculelor, modelul probabilistic este calculat ca o tabelă de valori pondere pentru fiecare posibilă înălțime, câte o tabelă pentru fiecare celulă. Acest proces se numește *Calculul Ponderilor Înălțimilor*. Odată calculate aceste ponderi, procesul ponderării particulelor devine o simplă asignare a unei valori din tabelă pentru înălțimea propusă de particulă. Detaliile acestui proces sunt descrise în secțiunea 4.4.

După ce fiecare particulă primește o pondere bazată pe potrivirea ei cu datele de măsură, o nouă populație de particule se va genera pentru fiecare celulă, prin procesul de *reeșantionare*. Ponderea particulei influențează șansele ei de a fi selectată pentru a forma noua populație. În acest fel, dacă particula are o înălțime apropiată de cea a măsurătorilor ea va supraviețui și se va înmulți, iar dacă nu ea va dispărea. Detalii sunt oferite în secțiunea 4.5.

Dacă o celulă din hartă are prea puține particule, sau niciuna, datele de măsură sunt utilizate pentru a crea noi particule, care vor avea viteze aleatoare și o distribuție de înălțimi compatibilă cu tabela de ponderi calculată. Procesul de creare a noilor particule este descris în secțiunea 4.7.

Având populația de particule actualizată, sistemul este pregătit pentru noul ciclu de urmărire. Deși rezultatul complet al procesului de urmărire este populația de particule propriu zisă, rezultatul util este o hartă dinamică de înălțimi cu o singură înălțime și un singur vector de viteză pentru fiecare celulă. Pasul numit *Estimare și Generare Ieșire* va calcula aceste valori, și va genera o descriere a scenei într-un limbaj de descriere 3D popular, pentru analiză și vizualizare. Acest proces este descris în secțiunea 4.8.

4. Descrierea algoritmului

4.1. Deplasarea și difuzia particulelor

Modelul probabilistic al tranziției stărilor este implementat prin deplasarea deterministă și difuzia stohastică a particulelor. Deplasarea deterministă schimbă starea particulelor prin luarea în calcul a doi factori: mișcarea vehiculului de observație, care cauzează o mișcare relativă a întregii scene în sistemul de coordonate al vehiculului, și mișcarea particulelor, pe baza vitezei lor proprii. Mișcarea vehiculului observator în planul XOY poate fi calculată din viteza v și viteza angulară $\dot{\psi}$, care sunt citite de pe magistrala CAN, fiind furnizate de senzori cu care sunt echipate autovehiculele de serie. Aceste viteze sunt integrate pe intervalul de timp dintre două măsurători, Δt . În acest timp, vehiculul se rotește cu unghiul ψ și se deplasează cu distanța d .

$$\psi = \dot{\psi} \Delta t \tag{6}$$

$$d = \frac{2v\Delta t \sin \frac{\psi}{2}}{\psi} \quad (7)$$

Luând în considerare dimensiunea celulei, $D_X \times D_Y$ (0.2 m x 0.2 m), originea sistemului de coordonate se deplasează cu d^c coloane și d^r rânduri:

$$d^c = d \sin \frac{\psi}{2} / D_Y \quad (8)$$

$$d^r = d \cos \frac{\psi}{2} / D_X \quad (9)$$

Datorită mișcării vehiculului observator, o particulă k din mulțimea de particule $S(t-1)$ cu coordonatele ${}_p r_k(t-1)$ și ${}_p c_k(t-1)$ va fi deplasată într-o nouă locație, la coordonatele ${}_p c_k^*(t)$ și ${}_p r_k^*(t)$ care se calculează ca:

$$\begin{pmatrix} {}_p c_k^*(t) \\ {}_p r_k^*(t) \end{pmatrix} = \begin{pmatrix} \cos \psi & -\sin \psi \\ \sin \psi & \cos \psi \end{pmatrix} \begin{pmatrix} {}_p c_k(t-1) \\ {}_p r_k(t-1) \end{pmatrix} - \begin{pmatrix} d^c \\ d^r \end{pmatrix} \quad (10)$$

Vectorul viteză al particulei, format din componentele ${}_p v_k^c(t-1)$ și ${}_p v_k^r(t-1)$, depinde și el de sistemul de coordonate al vehiculului. Din acest motiv, când vehiculul observator se rotește, vectorul viteză trebuie rotit în sens opus, pentru ca direcția lui în scenă să rămână nemodificată. Noul vector viteză are componentele ${}_p v_k^{c*}(t)$ și ${}_p v_k^{r*}(t)$:

$$\begin{pmatrix} {}_p v_k^{c*}(t) \\ {}_p v_k^{r*}(t) \end{pmatrix} = \begin{pmatrix} \cos \psi & \sin \psi \\ -\sin \psi & \cos \psi \end{pmatrix} \begin{pmatrix} {}_p v_k^c(t-1) \\ {}_p v_k^r(t-1) \end{pmatrix} \quad (11)$$

După corecția pozițiilor și a vitezelor particulelor pentru a compensa mișcarea proprie, procesul de deplasare este finalizat prin deplasarea particulelor datorită propriei lor viteze. După deplasare, particulele sunt supuse difuziei, unde se va adăuga stării fiecărei particule cantități aleatoare $\delta_p c(t), \delta_p r(t), \delta_p h(t), \delta_p v^c(t)$ și $\delta_p v^r(t)$, extrase dintr-o densitate de probabilitate normală de medie zero și matrice de covarianță ajustată experimental $\mathbf{Q}_i(t)$, care descrie incertitudinea tranziției stărilor. Procesul complet de predicție este descris de ecuația (12):

$$\begin{pmatrix} {}_p c_k(t) \\ {}_p r_k(t) \\ {}_p h_k(t) \\ {}_p v_k^c(t) \\ {}_p v_k^r(t) \end{pmatrix} = \begin{pmatrix} 1 & 0 & 0 & \Delta t & 0 \\ 0 & 1 & 0 & 0 & \Delta t \\ 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 1 \end{pmatrix} \begin{pmatrix} {}_p c_k^*(t) \\ {}_p r_k^*(t) \\ {}_p h_k(t) \\ {}_p v_k^{c*}(t) \\ {}_p v_k^{r*}(t) \end{pmatrix} + \begin{pmatrix} \delta_p c(t) \\ \delta_p r(t) \\ \delta_p h(t) \\ \delta_p v^c(t) \\ \delta_p v^r(t) \end{pmatrix} \quad (12)$$

După aplicarea ecuației predicției pentru fiecare particulă din scenă, pasul final este să ne asigurăm că fiecare celulă din hartă nu are un număr de particule mai mare decât N_C , numărul maxim de particule permis pentru o celulă (un parametru al sistemului, reglat experimental la valoarea 200). Din acest motiv, dacă prin predicție într-o celulă ajung mai multe particule decât limita maximă particulele în exces sunt distruse în mod aleator.

4.2. Datele de măsură: harta primară de înălțimi

Sursa măsurătorilor pentru algoritmul de urmărire este un sistem de stereoviziune densă [24], capabil să extragă informație 3D pentru aproape toate punctele din imagine. Punctele 3D sunt apoi atașate unor celule din planul XOY , iar pentru fiecare celulă se calculează o înălțime unică ca maximum înălțimilor punctelor din ea. De asemenea, se calculează și densitatea punctelor 3D din fiecare celulă, iar această densitate este folosită pentru o validare elementară a înălțimilor, aplicând condiția că zonele de drum sunt mai puțin dense în puncte ca zonele de tip obstacol. Această validare permite eliminarea înălțimilor foarte mari din celule cu densitate mică, înălțimi care sunt de obicei generate de erori la reconstrucția stereo. O descriere detaliată a metodei de generare a hărții primare de înălțimi se găsește în [9].

Pentru algoritmul de urmărire, se vor utiliza următoarele informații din harta de înălțimi primară:

- Înălțimea măsurată pentru fiecare celulă i , notată ca z_i . Pentru o mai bună accesare, înălțimile sunt organizate ca un tablou 2D de valori care pot fi accesate prin coordonate rând și coloană, astfel că vom scrie pe z_i ca $z(r_i, c_i)$.
- Disponibilitatea datelor pentru fiecare celulă, notată cu d_i . $d_i=1$ înseamnă că avem înălțime măsurată pentru celula i , iar $d_i=0$ înseamnă că celula nu are înălțime observată. Pentru eficiență, valorile d_i sunt organizate ca tablou 2D, ce poate fi accesat prin linie și coloană, deci d_i se poate scrie ca $d(r_i, c_i)$.

Deoarece nu toți pixelii din imagini vor primi informație 3D prin algoritmul de stereoviziune, și nu toate zonele din scenă sunt vizibile, din cauza ocluziilor și a câmpului vizual finit, nu toate celulele din harta primară vor avea înălțime măsurată. Informația despre disponibilitatea datelor, codificată ca d_i , ajută algoritmul de urmărire să țină cont de aceste limitări.

Un exemplu de hartă primară de înălțimi este prezentat în figura 4.




Fig. 4. Harta primară de înălțimi, extrasă prin stereoviziune [31]: a) imaginea originală în tonuri de gri; b) vedere de sus a hărții, cu înălțimile codificate ca valori de gri. Informația senzorială acoperă doar o mică parte din hartă, iar zonele care nu sunt procesate sunt albe; c) Reprezentare 3D a hărții primare. Zonele netexturate reprezintă zonele care nu au înălțime, datorită limitărilor sau a erorilor de reconstrucție.

4.3. Compensarea unghiului de aplecare

Conform modelului lumii descris în secțiunea 2, o particulă k este localizată la coordonata rând ${}_p r_k$ și coordonata coloană ${}_p c_k$, și are înălțimea ${}_p h_k$. Datorită naturii continue a procesului de observație, înălțimile hărții nu se vor schimba brusc de la un cadru la altul, cu excepția cazului când vehiculul de observație are o mișcare prin care își modifică unghiul de aplecare. Efectul variației unghiului de aplecare între două cadre, $\Delta\alpha$, este o diferență dintre înălțimea particulei și înălțimea măsurată în celula care conține particula:

$$\Delta\alpha_k = \tan^{-1} \left(\frac{({}_p h_k - z({}_p r_k, {}_p c_k)) D_H}{D_X {}_p r_k} \right) \quad (13)$$

Evident că ecuația (13) este validă doar dacă particula este statică, și înălțimea ei este apropiată de înălțimea adevărată a scenei. Aceste condiții nu sunt adevărate în cazul general, dar putem face câteva presupuneri:

- Majoritatea particulelor din scenă aparțin unor structuri statice. Acestea includ cea mai mare structură observabilă, suprafața drumului.
- Înălțimea medie în fiecare celulă este apropiată de cea reală, chiar dacă particulele individuale au deviații față de aceasta.
- Schimbările în înălțime datorită mișcărilor din scenă sunt minore comparative cu schimbările abrupte ale unghiului de aplecare.

Pe baza acestor presupuneri, ecuația (13) se poate media pentru toate particulele localizate în celule cu date valide, și se poate calcula o deviație medie a unghiului de aplecare între măsurători:

$$\Delta\alpha = \frac{\sum_{k=1}^{N_s} \tan^{-1} \left(\frac{({}_p h_k - z({}_p r_k, {}_p c_k)) D_H}{D_X {}_p r_k} \right) d({}_p r_k, {}_p c_k)}{\sum_{k=1}^{N_s} d({}_p r_k, {}_p c_k)} \quad (14)$$

După ce unghiul de aplecare este estimat, înălțimea ${}_p h_k$ a fiecărei particule k poate fi corectată:

$${}_p h_k = \frac{({}_p h_k D_H - \Delta\alpha {}_p r_k D_X)}{D_H} \quad (15)$$

4.4. Calculul ponderilor înălțimilor, și ponderarea particulelor

Procesul de ponderare a particulelor este particularizarea din punctul de vedere al filtrului de particule a modelului de observație $p(\mathbf{Z}(t) | \mathbf{X}_i(t) = \mathbf{x}_k(t))$, introdus în secțiunea 2. Acest model descrie densitatea de probabilitate condiționată a măsurătorii $\mathbf{Z}(t)$ dacă se presupune că starea celulei este $\mathbf{X}_i(t) = \mathbf{x}_k(t)$. O particulă este o ipoteză a stării, și probabilitatea condiționată a măsurătorii condiționată de starea particulei va fi codificată ca pondere a particulei, care va descrie cât de bine se potrivește ipoteza particulei cu datele de măsură.

Datele senzoriale, reprezentate sub forma hărții primare de înălțimi, sunt până la urmă doar o variantă mai convenabilă și un pic filtrată a informației 3D dată de stereoviziunea densă. Din acest motiv, modelul probabilistic al observației va fi derivat din modelul de observație al stereoviziunii, care este o densitate normală (Gaussiană) tridimensională centrată în coordonatele reale, având o matrice de covarianță definită de deviația standard a erorii distanței σ_X , de deviația standard a erorii coordonatei laterale σ_Y , și de deviația standard a erorii pe coordonata verticală, σ_z .

Deviațiile standard așteptate pentru erorile pe aceste axe de coordonate ale procesului de reconstrucție stereo depind de baseline-ul sistemului stereo (distanța dintre camere) b , de distanța focală calculată în pixeli f , și de incertitudinea la calculul disparităților σ_d . Procesul de reconstrucție stereo este văzut ca o transformare neliniară a vectorului (u, v, d) , ce conține poziția punctului în spațiul imaginii stângi, (u, v) , și disparitatea d , în vectorul coordonatelor 3D (X, Y, Z) . Eroarea este calculată prin propagarea matricei de covarianță a (u, v, d) prin liniarizarea Jacobiană a transformării pentru reconstrucția 3D [25]. Deviația standard pentru coordonata distanță X se calculează ca:

$$\sigma_X = \frac{X^2 \sigma_d}{bf} \quad (16)$$

Deviațiile standard pentru coordonata laterală Y și pentru coordonata verticală Z depind de deviația standard a erorii pentru distanță σ_X și de incertitudinea poziției în imagine (în pixeli)

σ_P .

$$\sigma_Y^2 = \frac{X^2}{f^2} \sigma_P^2 + \frac{Y^2}{X^2} \sigma_X^2 \quad (17)$$

$$\sigma_Z^2 = \frac{X^2}{f^2} \sigma_P^2 + \frac{Z^2}{X^2} \sigma_X^2 \quad (18)$$

Valorile primilor termeni ai sumelor din ecuațiile (17) și (18) sunt mult mai mici decât valorile următorilor termeni, și din acest motiv pot fi ignorate. Astfel, putem calcula σ_Y și σ_Z ca:

$$\sigma_Y = \frac{Y \sigma_X}{X} \quad (19)$$

$$\sigma_Z = \frac{Z \sigma_X}{X} \quad (20)$$

Ecuțiile de la (16) la (20) se referă la coordonatele 3D X , Y și Z din sistemul de referință al camerei, nu al autovehiculului. Pentru a putea aplica aceste ecuații pentru harta de înălțimi, fiecare celulă din această hartă va fi asociată unei coordonate 3D în sistemul de referință al camerei. O tabelă de valori, calculată la pornirea programului pe baza parametrilor extrinseci ai camerei în sistemul lumii (rotație și translație) va rezolva această problemă.

Tot prin tabele de valori, calculate la pornirea programului, pot fi menținute și incertitudinile pentru coordonatele X și Y , pentru fiecare celulă, deoarece poziția lor în hartă nu se schimbă. Singura coordonată variabilă pentru harta de înălțimi este coordonata Y , înălțimea.

Incertitudinile, calculate în unități de distanță (în cazul nostru în milimetri) sunt convertite în incertitudini de rând, coloană și înălțime discrete, folosind următoarele ecuații:

$$\sigma_r = \frac{\sigma_X}{D_X} + \sigma_{r0} \quad (21)$$

$$\sigma_c = \frac{\sigma_Y}{D_Y} + \sigma_{c0} \quad (22)$$

$$\sigma_h = \frac{\sigma_Z}{D_H} + \sigma_{h0} \quad (23)$$

Valorile fixe adăugate, σ_{r0} , σ_{c0} și σ_{h0} sunt folosite pentru a reprezenta alte surse de eroare în afară de incertitudinea reconstrucției stereo (de exemplu, potrivire incorectă datorită zonelor netexturate sau cu model repetitiv). Aceste valori sunt reglate experimental.

După calculul incertitudinilor pentru fiecare celulă, acestea pot fi transformate în ponderi care vor fi asignate particulelor. Modelul de măsură este reprezentat de o densitate Gaussiană centrată în valoarea reală a rândului, coloanei și înălțimii, având matricea de covarianță formată

pe baza celor trei deviații standard, σ_r , σ_c și σ_h . Deoarece acestea depind de celula i , le vom nota, în ecuațiile următoare, ca $\sigma_{r,i}$, $\sigma_{c,i}$ și $\sigma_{h,i}$.

Abordarea clasică pentru ponderarea particulelor ar fi, în această situație, calcularea distanței de la poziția și înălțimea particulei (pr_k, pc_k, ph_k) la valoarea măsurătorilor (r, c, z) din interiorul unei zone acceptabile de căutare, și transformarea acestei distanțe în valoare de probabilitate folosind funcția Gaussiană. Această abordare nu este eficientă computațional, și nu poate trata situația în care mai multe înălțimi sunt disponibile în același interval.

În locul abordării bazate pe distanță, procesul de *Calcul a Ponderilor Înălțimilor* va crea, pentru fiecare celulă i din hartă, o tabelă de valori de ponderi pentru fiecare înălțime posibilă (aceste înălțimi sunt reprezentate ca valori discrete, multiple de 1 cm, astfel că o tabelă de 300 de poziții va acoperi toate înălțimile relevante din scenă).

Crearea tabelii pentru ponderi este controlată de datele disponibile. Pentru fiecare celulă i , se va analiza o regiune de influență de dimensiune $4\sigma_{r,i} \times 4\sigma_{c,i}$ în jurul poziției centrale (r_i, c_i). Fiecare înălțime măsurată z din interiorul zonei de căutare va primi ca pondere valoarea funcției Gaussiene bivariate G_i centrată în (r_i, c_i), având deviațiile standard $\sigma_{r,i}$ și $\sigma_{c,i}$. Acesta este un mod de aplicare direct al modelului de observație Gaussian în planul orizontal.

Fiecare înălțime cu ponderea ei calculată va fi stocată în tabela ponderilor, care este de fapt o histogramă. Valoarea histogramei pentru fiecare înălțime candidată h , la coordonatele (r_i, c_i), pentru celula i , este calculată în mod formal ca:

$$H_i(h) = \sum_{\tau=r_i-2\sigma_{r,i}}^{r_i+2\sigma_{r,i}} \sum_{\kappa=c_i-2\sigma_{c,i}}^{c_i+2\sigma_{c,i}} d(\tau, \kappa) G_i(\tau - r_i, \kappa - c_i) \delta(z(\tau, \kappa) - h) \quad (24)$$

Procesul este ilustrat în figura 5:

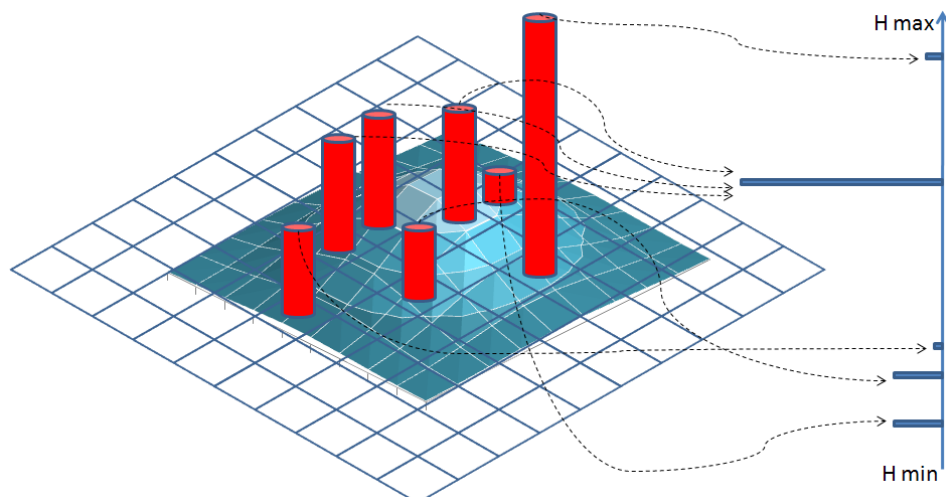


Fig. 5. Construirea histogramei de înălțimi pentru fiecare celulă [32]. O înălțime candidată, localizată în regiunea de influență, va avea un vot ponderat de valoarea nucleului Gaussian 2D centrat în celula curentă.

În ecuația (24) d este harta de disponibilitate a măsurătorilor, descrisă în secțiunea 4.2, iar δ este funcția Kronecker delta. Termenii $d(\tau, \kappa)$ și $\delta(z(\tau, \kappa) - h)$ indică faptul că doar celulele valide din harta primară care au înălțimea z egală cu înălțimea candidată h vor fi luate în considerare.

Conform modelului de măsură, ponderea particulei depinde de distanța ei față de măsurătoare pe toate cele trei axe de coordonate. Ecuația (24) ține cont doar de deplasarea în planul orizontal. Distanța dintre înălțimea particulei și una dintre înălțimile din histograma H_i poate fi transformată în valoare de probabilitate folosind tot o funcție Gaussiană. Pentru o mai mare eficiență, s-a ales soluția aplicării unei operații de convoluție pe histograma H_i cu un nucleu Gaussian unidimensional K_i , generat prin utilizarea unei deviații standard $\sigma_{h,i}$. Ecuația (25) va transforma histograma H_i , care conține doar valori sporadice ale înălțimii, într-o tabelă de valori continue W_i :

$$W_i = K_i * H_i \quad (25)$$

Tabela W_i poate fi utilizată acum pentru ponderarea particulelor. O particulă k , dintr-o celulă i , va primi următoarea pondere:

$$w_k = W_i(h_k) \quad (26)$$

Prin algoritmul de ponderare propus am reușit să ținem cont de incertitudinile stereo pe toate axele de coordonate, dar și de situația în care există mai multe măsurători conflictuale ale înălțimii în jurul unei celule date (funcția de măsură este multimodală). Dacă într-o celulă avem particule reprezentând înălțimi diferite, fiecare poate primi o pondere mare dacă datele de măsură conțin înălțimi potrivite pentru ele. În acest fel se pot urmări simultan ipoteze aparent conflictuale, care ar putea fi generate, de exemplu, de două obiecte de înălțimi diferite care pot să se întâlnească în aceeași celulă.

4.5. Reșantionare

Procesul de reșantionare creează o nouă populație de particule, folosind populația curentă și ponderile calculate prin procedeul de măsură. Acesta este pasul care face ca populația de particule să reflecte densitatea de probabilitate posterioară a stării urmărite, o densitate care este combinația dintre predicție (deplasare și difuzie) și măsură (ponderare).

Reșantionarea este aplicată pentru fiecare celulă i , la fiecare moment de timp t , după ce particulele sunt ponderate. Numărul total de particule dintr-o celulă este N_C , o constantă care este stabilită prin experiment la valoarea 200. Numărul real de particule dintr-o celulă, $N_{R,i}$, este dat de deplasare și de difuzie, și poate fi mai mic decât N_C .

Pentru reșantionare, vom presupune că celula are mai multe particule decât maximum permis, $N_A = 1.25 N_C$. Diferența dintre numărul de particule reale din celulă, $N_{R,i}$, și maximum amplificat N_A , este numărul de particule “goale”, particule care sunt de fapt spații neocupate.

Mecanismul de reeșantionare va executa următorii pași:

1. Se ponderează particulele goale cu o pondere implicită de valoare mică, pe care o alegem ca valoarea medie a tabelii de ponderi de înălțimi, W_i .
2. Se normalizează ponderile tuturor celor N_A particule astfel încât suma lor să devină 1.
3. Se fac un număr de N_C extrageri aleatoare din populația totală de particule, reale și goale. Ponderea particulei influențează șansele ei de a fi selectată – particulele cu pondere mare vor fi selectate de mai multe ori, iar cele cu pondere mică deloc. Dacă se selectează particule goale, numărul final de particule dintr-o celulă va fi mai mic decât N_C .

Mecanismul de reeșantionare va înlocui complet particulele dintr-o celulă la fiecare pas t (la fiecare cadru). Din acest motiv, nu e nevoie de o eliminare explicită a particulelor, pentru că cele cu pondere mică, ce nu se potrivesc cu datele de măsură, nu vor fi selectate și astfel vor fi eliminate automat.

Acest algoritm de reeșantionare diferă puțin față de soluția clasică descrisă în [23] datorită utilizării particulelor goale. Efectul acestor particule este următorul:

1. Dacă majoritatea particulelor reale dintr-o celulă au o pondere mică pentru că nu se potrivesc cu măsurătorile, populația dintr-o celulă scade.
2. Diferența dintre N_A și N_C dă posibilitatea de a se crea întotdeauna loc pentru particule noi, chiar dacă există o bună potrivire dintre particulele din celulă și măsurătoare.

Motivul principal pentru care a fost proiectat mecanismul de reducere a numărului particulelor dintr-o celulă, un mecanism care acționează în mod accelerat când datele nu se potrivesc cu predicția, este nevoia de a crea spațiu pentru particulele care aparțin obiectelor în mișcare. Dacă un autovehicul se deplasează pe o suprafață de drum, particulele cu înălțime joasă trebuie să fie eliminate pentru ca particulele înalte să poată intra în celulă. Fără o eliminare accelerată a particulelor nepotrivite, convergența populației particulelor la noua înălțime va fi lentă, iar sistemul nu va reacționa destul de rapid la o scenă dinamică.

4.4. Crearea particulelor noi

Dacă numărul de particule într-o celulă, $N_{R,i}$, este mai mic decât $N_C/2$, și celula i are o înălțime măsurată validă $z(r_i, c_i)$ în harta de măsură primară, algoritmul va crea un număr de $N_C/2 - N_{R,i}$ particule noi. Vitezele noilor particule vor fi extrase dintr-o densitate normală de probabilitate centrată în 0, iar ponderile vor fi extrase din densitatea multi-modală a înălțimilor măsurate care influențează celula i , reprezentată de tabela de ponderi W_i . Procesul de creare de noi particule este aplicat după pasul de reeșantionare.

4.5. Estimare și vizualizare

Dacă populația de particule dintr-o celulă i este mai mare de un prag pe care îl stabilim ca $2N_C/3$, se poate estima înălțimea și viteza medie din celulă prin medierea valorilor tuturor particulelor k din celula respectivă, folosind ecuațiile (27) și (28). Prin $|S|$ notăm cardinalitatea mulțimii S , numărul elementelor din S . Particulele implicate în estimare sunt cele generate prin reeșantionare, a căror pondere nu mai este relevantă.

$$h_i = \frac{\sum_{\mathbf{x}_k \in S, {}_p c_k = c_i, {}_p r_k = r_i} {}_p h_k}{|\{\mathbf{x}_k \in S \mid {}_p r_k = r_i, {}_p c_k = c_i\}|} \quad (27)$$

$$(v_i^c, v_i^r) = \frac{\sum_{\mathbf{x}_k \in S, {}_p c_k = c_i, {}_p r_k = r_i} ({}_p v_k^c, {}_p v_k^r)}{|\{\mathbf{x}_k \in S \mid {}_p r_k = r_i, {}_p c_k = c_i\}|} \quad (28)$$

Harta dinamică de înălțimi estimată este transformată într-o scenă VRML (Virtual Reality Modeling Language) [26], pentru a putea fi evaluată vizual, după cum se poate vedea în figura 6 (6.a și 6.b).

Din harta de înălțimi se poate deriva și o hartă de ocupare, probabilitatea de ocupare din fiecare celulă fiind calculată ca raportul dintre particulele cu înălțimea peste un prag T și numărul total de particule din celulă. În figura 6.d se poate vedea harta de ocupare generată din harta de înălțimi bazată pe particule, pentru un prag $T=50$ cm.

$$P_{Occ}(i) = \frac{|\{\mathbf{x}_k \in S \mid {}_p r_k = r_i, {}_p c_k = c_i, {}_p h_k > T\}|}{|\{\mathbf{x}_k \in S \mid {}_p r_k = r_i, {}_p c_k = c_i\}|} \quad (29)$$




Fig. 6. Rezultatele estimării pentru scena urmărită [31]: a) Vizualizare 3D a hărții de înălțime estimată, cu vectori viteză, în vedere perspectivă; b) Vizualizare 3D a hărții de înălțime estimată, cu vectori viteză, în vedere laterală; c) Vedere de sus a hărții urmărite, cu înălțimile codificate ca valori de nivele de gri; d) Estimare a hărții de ocupare pentru harta urmărită, valorile de probabilitate mare fiind reprezentate ca nuanțe mai închise.

5. Teste și rezultate

5.1. Evaluarea acurateții reconstrucției scenei

Cel mai important obiectiv al unui algoritm de estimare a unei hărți de înălțimi este să descrie cât mai precis scena observată. Din acest motiv, vom compara harta estimată cu o hartă cu înălțimi cunoscute precis, o hartă generată prin utilizarea unui senzor care are o mare precizie de măsură, și generează puncte cu o densitate comparabilă cu cea a unui senzor stereo. Din fericire, Karlsruhe Institute of Technology a realizat baza de date KTTI Vision Benchmark Suite [27], o colecție de secvențe conținând perechi de imagini color și în nuanțe de gri, puncte 3D măsurate cu senzorul laser Veodyne, date GPS, toate sincronizate și calibrate. Pentru evaluare, am parcurs următorii pași:

1. Aplicarea algoritmilor de reconstrucție prin stereoviziune pe perechile de imagini rectificatice ale bazei de date KITTI.
2. Calculul hărții de înălțimi primare, folosind punctele 3D obținute prin stereoviziune.
3. Urmărirea hărții de înălțimi folosind mecanismul bazat pe particule, utilizând harta primară ca măsurătoare.
4. Calculul unei hărți de înălțimi statice folosind punctele 3D date de senzorul Veoldyne. Această hartă este considerată referința pentru testare.
5. Calcularea diferențelor dintre harta de referință și harta stereo primară, și a diferențelor dintre harta de referință și harta urmărită. Diferențele sunt calculate doar pentru celulele care au înălțime validă și în harta de referință și în hărțile comparate cu ea.

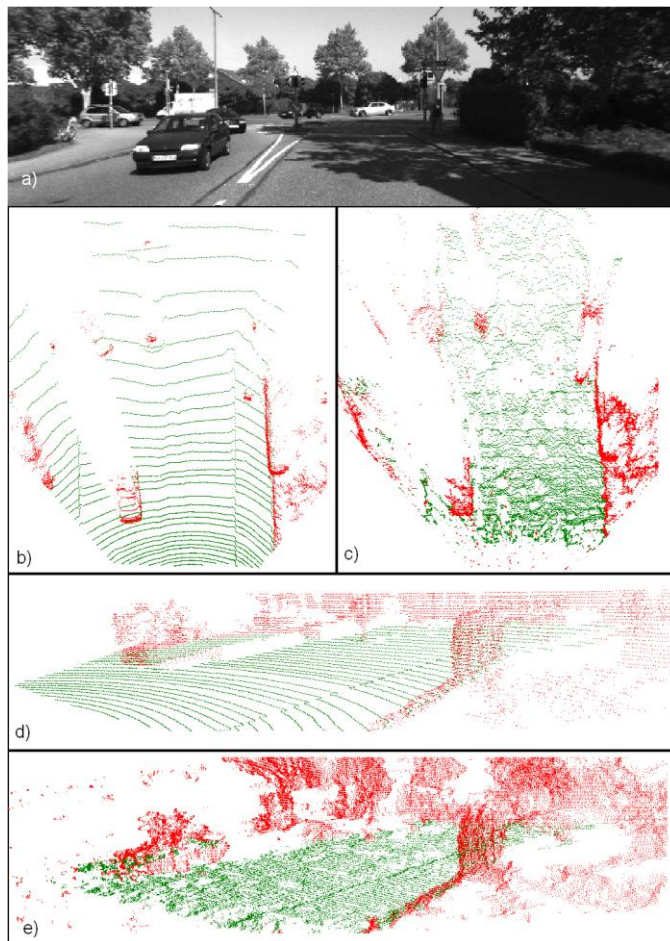


Fig. 7. Un cadru din secvența de evaluare [31]: a) imaginea de nivele gri stângă; b) punctele 3D date de laser, vedere de sus; c) punctele 3D date de stereo, vedere de sus; d) punctele 3D date de laser, vedere laterală; e) punctele 3D date de stereo, vedere laterală.

Analiza erorilor a fost realizată pe secvența 2011_09_26_drive_0009, parte a datelor de tip “raw” ce se pot descărca de la adresa [28]. În figura 7 putem vedea o comparație dintre punctele 3D reconstruite prin stereo, și punctele 3D date de senzorul laser, pentru un cadru din secvență.

Pe baza diferențelor dintre hărțile derivate din stereo (primară și urmărită) și cea dată de laser, ca referință, putem calcula trei indicatori:

- Procentul de înălțimi calculate greșit (Badly Computed Heights - BCH%), raportul dintre numărul de înălțimi cu diferența absolută față de referință mai mare decât un prag T (reglat la 0.15 m), și numărul total de înălțimi comparate cu referința.
- Eroarea pătratică medie (Root Mean Square Error - RMSE), o eroare medie a estimării în

comparație cu referința.

- Procentul de densitate, raportul dintre numărul de celule cu înălțime estimată și numărul total de celule care au înălțime în harta de referință (celulele observabile).

Primele două măsuri sunt inspirate din [29], o lucrare care definește indicatorii cei mai folosiți pentru evaluarea algoritmilor de stereoviziune, indicatori pe care îi considerăm potriviți și pentru evaluarea hărților de înălțimi.

TABEL I
COMPARAȚIE A PERFORMANȚEI PENTRU ESTIMAREA ÎNĂLȚIMILOR

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

Rezultatele pe toată secvența sunt prezentate în Tabelul 1. Se poate observa clar cum urmărirea hărții duce la o reducere a BCH% și a RMSE, în timp ce densitatea crește cu aproape 50%. Aceasta înseamnă că harta urmărită este o descriere mai completă a scenei, mai multe celule având înălțime validă, iar această creștere se obține fără a sacrifica precizia, ci chiar cu o îmbunătățire a acesteia.

Graficele din figura 8 prezintă situația BCH% pentru diferite distanțe și înălțimi de referință. Nu este o surpriză că erorile cresc cu distanța, acest lucru fiind un efect intrinsec al stereoviziunii. De asemenea, erorile cresc cu înălțimea observată, un fenomen care credem că este legat tot de incertitudinile de distanță. O structură înaltă estimată la distanța greșită va avea o eroare foarte mare față de referința care este de tip șosea.

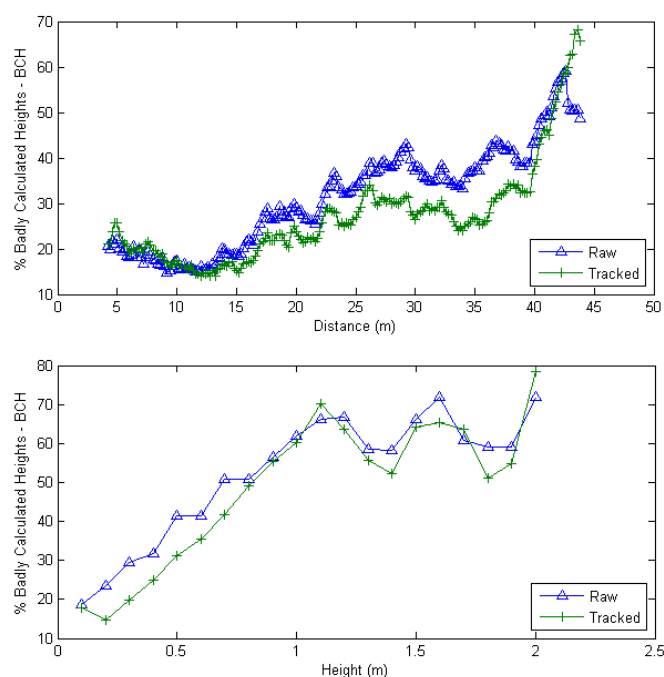


Fig. 8. Comparație pe procentul înălțimilor calculate greșit (BCH%) [31]. Albastru – harta primară, verde – harta urmărită. Sus: comparație BCH raportate la distanța față de vehiculul observator. Jos: comparație BCH raportate la înălțimile măsurate.

Graficele din figura 9 arată situația erorilor RMSE pentru diferite distanțe și înălțimi. După cum este de așteptat, erorile cresc cu distanța și cu înălțimea măsurată. Din figurile 8 și 9 se poate vedea clar că urmărirea îmbunătățește rezultatele în mod consistent, pentru aproape toate distanțele și înălțimile măsurate.




Fig. 9. Comparația erorilor pătratice medii (RMSE)[31]. Albastru – harta primară, verde – harta urmărită. Sus: comparație RMSE raportate la distanța față de vehiculul observator. Jos: comparație RMSE raportate la înălțimile măsurate.

5.2. Evaluarea acurateții de estimare a vitezelor

În afara faptului că urmărirea hărții de înălțimi crește acuratețea estimării înălțimilor din scena analizată, acest algoritm adaugă descrierii și informație dinamică. Pentru fiecare celulă din hartă se estimează un vector viteză, cu magnitudine și orientare, pe baza vitezelor individuale ale particulelor asociate celulei. Pentru a evalua calitatea estimării vitezei, vom utiliza secvențe înregistrate în condiții controlate, unde se cunoaște viteza obstacolului urmărit. În cele ce urmează vom prezenta analiza a opt secvențe, patru dintre ele cu obstacolul venind din față, la un unghi de 45 de grade (figura 10), și patru cu obstacolul venind din spate, la aceeași orientare (figura 11). Fiecare scenariu a fost repetat la viteze diferite: 30, 40, 50 și 60 km/h. Vehiculul țintă își atinge viteza stabilă în afara câmpului nostru vizual.

Fiecare secvență durează între 2 și 5 secunde (40 ... 100 cadre), și, în funcție de viteză, vehiculul este observat pentru o perioadă de 50 ... 70% din durata secvenței. Deoarece secvența conține doar vehiculul de test și șoseaua, vom analiza viteza tuturor particulelor din scenă cu înălțimea peste 50 cm.




Fig. 10. Test de estimare a vitezelor, cu vehiculul țintă apropiindu-se la 45 de grade [31]: a) imaginea stângă; b) harta de înălțime primară; c) harta de înălțime urmărită; d) harta de înălțime urmărită cu vectori de viteză.




Fig. 11. Test de estimare a vitezelor, cu vehiculul țintă îndepărtându-se la 45 de grade[31]. a) imaginea stângă; b) harta de înălțime primară; c) harta de înălțime urmărită; d) harta de înălțime urmărită cu vectori de viteză.

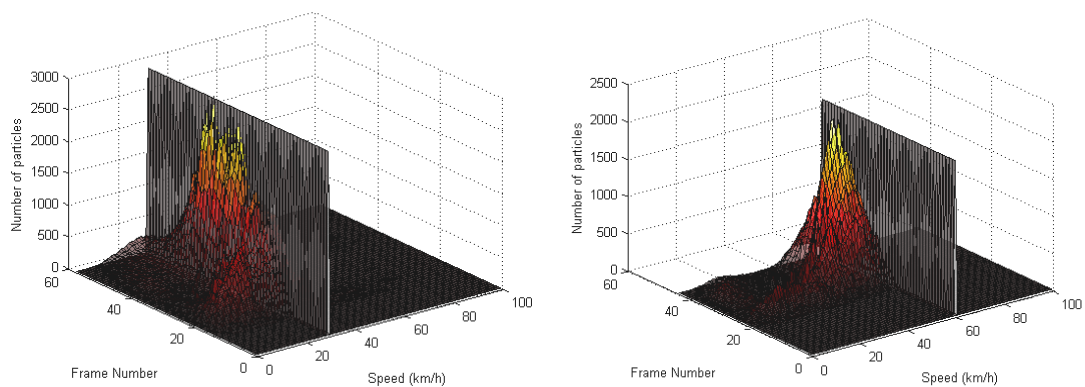


Fig. 12. Histogramele vitezelor particulelor, pentru scenariile cu vehiculul care se apropie [31]. Stânga: evoluția histogramelor pentru viteza de 30 km/h; Dreapta: evoluția histogramelor pentru viteza de 60 km/h.

În prima fază au fost calculate histograme pentru magnitudinea vitezei, care calculează numărul de particule pentru fiecare magnitudine posibilă, de la 0 la 100 km/h. Figurile 12 și 13 prezintă evoluția în timp a acestor histograme, desenată ca suprafață 3D, pentru vitezele reale de 30 km/h și de 60 km/h, pentru cele două orientări ale vehiculului urmărit. Viteza reală este desenată ca un plan vertical. Din cele patru grafice se poate observa mecanismul de aglomerare a ipotezelor vitezei: pe măsură ce vehiculul intră în scenă, histograma devine tot mai îngustă în jurul valorii corecte, și devine din nou difuză când vehiculul iese din câmpul vizual dar rămâne încă pe harta urmărită.




Fig. 13. Histogramele vitezelor particulelor, pentru scenariile cu vehiculul care se îndepărtează [31]. Stânga: evoluția histogramelor pentru viteza de 30 km/h; Dreapta: evoluția histogramelor pentru viteza de 60 km/h.

Pe baza histogramelor vitezelor, putem estima viteza percepută a obstacolului urmărit. Pentru cele două scenarii de orientare, au fost făcute grafice pentru vitezele estimate, comparativ cu vitezele reale, după cum se poate vedea în figura 14.

Pentru fiecare secvență a fost analizată eroarea de estimare a vitezei, luând în considerare doar cadrele în care obiectul urmărit este vizibil. Vitezele medii estimate, și erorile medii pătratice față de viteza de referință, sunt prezentate în tabelele II și III.

TABEL II
EVALUAREA MĂSURĂRII VITEZEI – SCENARIUL VEHICULULUI CARE SE APROPIE

Viteza de referință (km/h)	Viteza estimată medie (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

Graficele din figurile 12-14 și tabelele II și III arată că algoritmul de urmărire a hărților de înălțimi poate estima în mod robust viteza obiectelor în mișcare. Eroarea estimării crește cu viteza obiectului urmărit, un comportament care este de așteptat, deoarece o viteză mai mare înseamnă o deviație mai mare față de viteza inițială a celulei, care este zero (când o celulă este populată cu particule, acestea primesc valori aleatoare ale vitezei, extrase dintr-o densitate de probabilitate de medie zero). Procesele de deplasare și de reeșantionare vor elimina treptat vitezele greșite și vor înmulți pe cele corecte, dar aceste mecanisme nu acționează instantaneu.

Cu cât obiectul observat se deplasează mai repede, cu atât mai puțin timp avem pentru a-l observa, și astfel intervalul de timp în care viteza este stabil estimată este mai mic.

TABEL III
EVALUAREA MĂSURĂRII VITEZEI – SCENARIUL VEHICULULUI CARE SE ÎNDEPĂRTEAZĂ

Viteza de referință (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

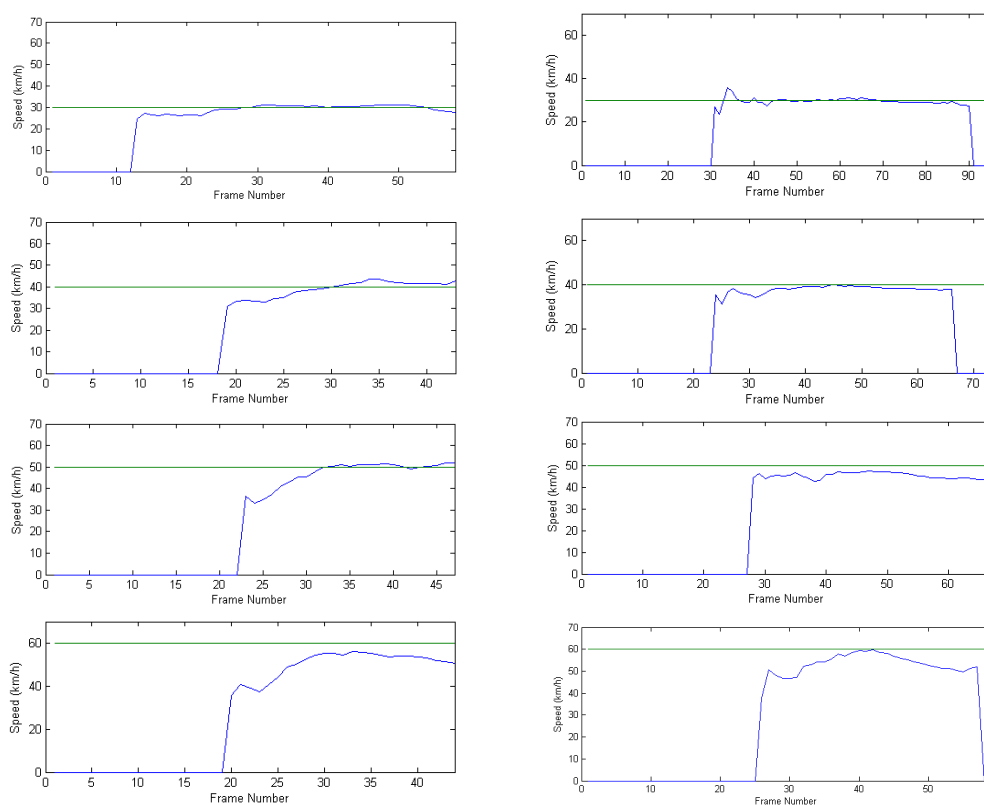


Fig. 14. Vitezele estimate, pentru viteze de referință de 30, 40, 50 și 60 km/h [31]. Stânga: scenariul vehiculului care se apropie. Dreapta: scenariul vehiculului care se îndepărtează.

5.3. Evaluare calitativă

Sistemul de urmărire a hărții de înălțimi a fost testat pe multiple secvențe de trafic real, capturate pe străzile din Cluj-Napoca, România. Modelele 3D rezultate ale mediului perceput au fost comparate cu imaginile originale, și au fost studiate următoarele caracteristici: similaritatea modelului rezultat cu scena reală, orientarea vectorilor viteză și magnitudinea lor aproximativă (descriind mișcarea generală a obiectelor din scenă), densitatea de estimare, și erorile evidente. Sistemul s-a dovedit capabil să abordeze scenariile complexe de trafic într-o manieră robustă, crescând calitatea estimării înălțimilor față de harta primară obținută prin stereoviziune. Câteva cadre reprezentative sunt prezentate în figurile 15, 16 și 17.

Un fișier video de înaltă rezoluție, care prezintă comportamentul sistemului pe o secvență de două minute, poate fi descărcat de la adresa din referința [30].




Fig. 15. Structuri mari statice și continue [31]: a) imaginea stângă; b) harta primară, cu înălțimea codificată ca intensitate; c) harta urmărită, cu înălțimea codificată ca intensitate; d) estimarea hărții de ocupare; e) harta primară, vizualizare 3D, vedere perspectivă; f) harta primară, vizualizare 3D, vedere laterală; g) harta urmărită, vizualizare 3D, vedere perspectivă; h) harta urmărită, vizualizare 3D, vedere laterală.




Fig. 16. Urmărire pietoni, cu vectorii de viteză estimați [31]: a) imaginea stângă; b) harta primară, cu înălțimea codificată ca intensitate; c) harta urmărită, cu înălțimea codificată ca intensitate; d) estimarea hărții de ocupare; e) harta primară, vizualizare 3D, vedere perspectivă; f) harta primară, vizualizare 3D, vedere laterală; g) harta urmărită, vizualizare 3D, vedere perspectivă; h) harta urmărită, vizualizare 3D, vedere laterală.




Fig. 17. Urmărirea autovehiculelor prin intersecție [31]: a) imaginea stângă; b) harta primară, cu înălțimea codificată ca intensitate; c) harta urmărită, cu înălțimea codificată ca intensitate; d) estimarea hărții de ocupare; e) harta primară, vizualizare 3D, vedere perspectivă; f) harta primară, vizualizare 3D, vedere laterală; g) harta urmărită, vizualizare 3D, vedere perspectivă; h) harta urmărită, vizualizare 3D, vedere laterală.

5.4. Comparație a modurilor de reprezentare a lumii




Fig. 18. Percepția bazată pe cuboide (sus) comparată cu percepția prin harta dinamică de înălțimi (jos), într-un sens giratoriu [31].

Cu toate că reprezentarea clasică a obstacolelor ca paralelipede orientate rămâne cea mai populară alegere pentru sistemele de percepție a mediului din domeniul asistenței conducerii auto, de-a lungul anilor au fost propuse alternative variate, care au încercat să crească flexibilitatea reprezentării și nivelul de detaliu perceput.

Metoda descrisă în acest capitol reprezintă mediul ca o hartă de înălțimi probabilistică complet dinamică, cu densitate multimodală de probabilitate a stării celulelor. În tabelul IV se prezintă

o comparație neexhaustivă cu metodele existente de descriere a mediului, folosind următoarele caracteristici: flexibilitate (capabilitatea de a descrie obstacole cu formă liberă), capabilitatea de reprezentare și estimare a vitezelor, densitate și capabilitatea de reprezentare și estimare a înălțimilor. Tabelul arată că modelul hărții dinamice de înălțimi combină avantajele hărții de înălțimi statice cu cele ale hărții dinamice de ocupare, fiind cea mai fidelă reprezentare a lumii reale.

TABEL IV
COMPARAȚIE A HĂRȚII DINAMICE DE ÎNĂLȚIMI CU ALTE METODE DE MODELARE A MEDIULUI

Metodă	Descriere flexibilă a formeii	Estimarea vitezei	Densitate	Estimare a înălțimii
<i>Cuboide orientate</i> [17]	Nu	Da	Mică	Da
<i>Hartă de înălțimi</i> [11][12]	Da	Nu	Mare	Da
<i>Hartă de ocupare dinamică</i> [2][21]	Da	Da	Mare	Nu
<i>Viziune 6D</i> [4]	Da	Da	Mică	Da
<i>Stixel dinamic</i> [5]	Da	Da	Mică	Da
<i>Hartă dinamică de înălțimi</i>	Da	Da	Mare	Da

În figura 18 putem vedea o comparație între reprezentarea clasică, bazată pe cuboide, și percepția pe baza hărții dinamice de înălțimi. Situația este una foarte relevantă pentru asistența conducerii, și anume navigarea unui sens giratoriu. Se poate observa că natura curbată și înălțimea redusă a insulei centrale a sensului giratoriu nu sunt descrise bine de cuboidele orientate, în timp ce harta de înălțimi descrie scena fidel.

6. Concluzii și perspective

În acest capitol a fost descrisă o metodă de modelare și urmărire a mediului 3D din traficul auto, harta dinamică de înălțimi bazată pe particule. Elementul de bază al modelului propus este particula dinamică având poziție, viteză și înălțime, care poate popula celulele hărții, poate migra între aceste celule, și poate fi creată, multiplicată sau distrusă pe baza datelor de măsură. Folosind mulțimea particulelor, a fost proiectat un sistem elegant, intuitiv și ușor adaptabil pentru a rezolva problema Bayesiană de urmărire a unei densități de probabilitate nonparametrice pentru harta digitală dinamică de înălțimi. Ideea de bază a particulelor mobile ca mecanism de inferență a fost descrisă în capitolul IV, și a fost extinsă pentru a putea aborda cu succes o dimensiune suplimentară, înălțimea. Tipul de măsurătoare folosit este acum harta primară de înălțimi, ceea ce a dus la dezvoltarea unui model probabilistic de măsură nou.

Sistemul de urmărire rezultat unifică urmărirea lumii dinamice pe bază de celule, specifică hărților dinamice de ocupare, cu puterea de descriere a hărții de înălțimi. Deși există și alte soluții pentru a trata mișcarea din scenă, sau de a combina harta de înălțimi cu cea de ocupare, soluția descrisă aici poate urmări harta de înălțimi dinamică în mod direct, într-o manieră uniformă, fără a face diferența dintre o celulă ocupată sau liberă, statică sau dinamică. Harta dinamică este o reprezentare generală a lumii 3D, care se poate transforma ușor într-o reprezentare mai specifică precum harta de ocupare, după cum a fost demonstrat.

Algoritmul de urmărire se poate adapta ușor la alte surse de măsură, precum scannerul laser. Au fost făcute experimente pentru adaptarea acestui algoritm la datele de măsură Velodyne folosite ca referință pentru experimente, și rezultatele arată promițător. Din acest motiv, considerăm că această reprezentare ar putea fi folosită ca platformă de fuzionare a datelor provenite de la mai mulți senzori, combinând, de exemplu, stereoviziunea cu laserul.

Sistemul rezultat nu este, din păcate un sistem care poate să urmărească scena în timp real. Timpul de procesare pe cadru este aproximativ 500 ms, pe un procesor clasic cu un singur fir de execuție. Pentru atingerea performanțelor de timp ce ar permite utilizarea acestui sistem într-o aplicație de asistență a conducerii este nevoie de paralelizare masivă pe arhitecturi de tip GPU.

7. Bibliografie

- [1] B. Gassmann, L. Frommberger, R. Dillmann, K. Berns, "Real-time 3D map building for local navigation of a walking robot in unstructured terrain," *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2003)*, 2003, pp. 2185-2190 vol.3.
- [2] C. Coué, C. Pradalier, C. Laugier, T. Fraichard, P. Bessière, "Bayesian Occupancy Filtering for Multitarget Tracking: An Automotive Application," *International Journal of Robotics Research*, vol. 25, pp. 19-30, January 1, 2006.
- [3] C. Brenneke, O. Wulf, B. Wagner, "Using 3D laser range data for SLAM in outdoor environments," *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2003)*, 2003, pp. 188-193 vol.1.
- [4] U. Franke, C. Rabe, H. Badino, S. K. Gehrig, "6D-Vision: Fusion of Stereo and Motion for Robust Environment Perception," in *DAGM-Symposium* vol. 3663, ed: Springer, 2005, pp. 216-223.
- [5] D. Pfeiffer, U. Franke, "Efficient representation of traffic scenes by means of dynamic stixels," *IEEE Intelligent Vehicles Symposium (IV 2010)*, 2010, pp. 217-224.
- [6] D. F. Huber, M. Hebert, "A new approach to 3-D terrain mapping," in *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS '99)* 1999, pp. 1121-1127 vol.2.
- [7] M. Vergauwen, M. Pollefeys, L. Van Gool, "A stereo-vision system for support of planetary surface exploration," *Machine Vision Applications*, vol. 14, pp. 5-14, 2003.
- [8] S. Lacroix, A. Mallet, D. Bonnafous, G. Bauzil, S. Fleury, M. Herrb, R. Chatila, "Autonomous Rover Navigation on Unknown Terrains: Functions and Integration," *International Journal of Robotics Research*, vol. 21, pp. 917-942, October 1, 2002.
- [9] F. Oniga, S. Nedevschi, "Processing Dense Stereo Data Using Elevation Maps: Road Surface, Traffic Isle, and Obstacle Detection," *IEEE Transactions on Vehicular Technology*, vol. 59, pp. 1172-1182, 2010.
- [10] M. Harville, "Stereo person tracking with adaptive plan-view templates of height and occupancy statistics," *Image and Vision Computing*, vol. 22, pp. 127-142, 2004.
- [11] P. Pfaff, R. Triebel, W. Burgard, "An Efficient Extension to Elevation Maps for Outdoor Terrain Mapping and Loop Closing," *International Journal of Robotics Research*, vol. 26, pp. 217-230, February 1, 2007.
- [12] R. Triebel, P. Pfaff, W. Burgard, "Multi-Level Surface Maps for Outdoor Terrain Mapping and Loop Closing," *IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2006)* 2006, pp. 2276-2282.

- [13] I. Dryanovski, W. Morris, X. Jizhong, "Multi-volume occupancy grids: An efficient probabilistic 3D mapping model for micro aerial vehicles," IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS 2010), 2010, pp. 1553-1559.
- [14] A. Elfes, "Using occupancy grids for mobile robot perception and navigation," Computer, vol. 22, pp. 46-57, 1989.
- [15] C. Chen, C. Tay, C. Laugier, K. Mekhnacha, "Dynamic Environment Modeling with Gridmap: A Multiple-Object Tracking Application," in 9th International Conference on Control, Automation, Robotics and Vision (ICARCV '06), 2006, pp. 1-6.
- [16] J. Moras, V. Cherfaoui, P. Bonnifait, "Moving Objects Detection by Conflict Analysis in Evidential Grids," 2011 IEEE Intelligent Vehicles Symposium, pp. 1122-1127, 2011.
- [17] T. N. Nguyen, B. Michaelis, A. Al-Hamadi, M. Tornow, M. M. Meinecke, "Stereo-Camera-Based Urban Environment Perception Using Occupancy Grid and Object Tracking," IEEE Transactions on Intelligent Transportation Systems, vol. 13, pp. 154-165, Mar 2012.
- [18] M. Perrollaz, J. D. Yoder, A. Negre, A. Spalanzani, C. Laugier, "A Visibility-Based Approach for Occupancy Grid Computation in Disparity Space," IEEE Transactions on Intelligent Transportation Systems, vol. 13, pp. 1383-1393, Sep 2012.
- [19] M. Kumar, D. P. Garg, "Three-Dimensional Occupancy Grids With the Use of Vision and Proximity Sensors in a Robotic Workcell," ASME Conference Proceedings, vol. 2004, pp. 1029-1036, 2004.
- [20] H. Lategahn, W. Derendarz, T. Graf, B. Kitt, J. Effertz, "Occupancy grid computation from dense stereo and sparse structure and motion points for automotive applications," IEEE Intelligent Vehicles Symposium (IV 2010) 2010, pp. 819-824.
- [21] R. Danescu, F. Oniga, S. Nedevschi, "Modeling and Tracking the Driving Environment With a Particle-Based Occupancy Grid," IEEE Transactions on Intelligent Transportation Systems, vol. 12, pp. 1331-1342, 2011.
- [22] M. S. Arulampalam, S. Maskell, N. Gordon, T. Clapp, "A tutorial on particle filters for online nonlinear/non-Gaussian Bayesian tracking," IEEE Transactions on Signal Processing, vol. 50, pp. 174-188, 2002.
- [23] M. Isard, A. Blake, "CONDENSATION—Conditional Density Propagation for Visual Tracking," International Journal of Computer Vision, vol. 29, pp. 5-28, 1998.
- [24] C. D. Pantilie, S. Nedevschi, "SORT-SGM: Subpixel Optimized Real-Time Semiglobal Matching for Intelligent Vehicles," IEEE Transactions on Vehicular Technology, vol. 61, pp. 1032-1042, 2012.
- [25] O. Faugeras, "Three-Dimensional Computer Vision: A Geometric Viewpoint", MIT Press, 1993.
- [26] WWWConsortium, "VRML Virtual Reality Modeling Language", disponibil la adresa: <http://www.w3.org/Markup/VRML/>
- [27] A. Geiger, P. Lenz, R. Urtasun, "Are we ready for autonomous driving? The KITTI vision benchmark suite," IEEE Conference on Computer Vision and Pattern Recognition (CVPR 2012), 2012, pp. 3354-3361.
- [28] A. Geiger, "The KITTI Vision Benchmark Suite - Raw Data", disponibil la adresa: http://www.cvlibs.net/datasets/kitti/raw_data.php
- [29] D. Scharstein, R. Szeliski, "A Taxonomy and Evaluation of Dense Two-Frame Stereo Correspondence Algorithms," International Journal of Computer Vision, vol. 47, pp. 7-42, 2002.
- [30] R. Danescu, "Dynamic Elevation Map Tracking Demo Video", disponibil la adresa: <http://users.utcluj.ro/~rdanescu/dynamap.avi>
- [31] R. Danescu, S. Nedevschi, "A Particle-Based Solution for Modeling and Tracking Dynamic Digital Elevation Maps ", IEEE Transactions on Intelligent Transportation Systems, vol. 15, nr. 3, pp. 1002-1015, 2014.

[32] R. Danescu, S. Nedevschi, "A Flexible Solution for Modeling and Tracking Generic Dynamic 3D Environments", 16th International IEEE Conference on Intelligent Transportation Systems (ITSC), 2013, pp. 1686-1692.

Mulțumiri

Rezultatele descrise în această carte au fost obținute în urma activității mele de cercetare în cadrul colectivului de cercetare Image Processing and Pattern Recognition Research Center (IPPRC), condus de domnul profesor Sergiu Nedevschi. Îi mulțumesc domnului profesor pentru că m-a introdus în domeniul viziunii artificiale, și apoi m-a îndrumat, în calitate de conducător de diplomă, de masterat și de doctorat, spre înalta performanță în cercetare.

Tot meritul domnului profesor este atragerea de finanțare pentru activitatea de cercetare a mea și a colegilor mei. Această finanțare a venit în primii ani mai ales din partea companiei Volkswagen AG Germania, care a avut încredere să finanțeze un mic grup de cercetare dintr-o mică țară a Europei de Est pentru proiectarea și dezvoltarea de soluții bazate pe stereoviziune, un domeniu de pionierat în acei ani. Mulțumesc lui Hans Joachim Grove și soției lui, Maria Grove, pentru facilitarea acestei colaborări, și cercetătorilor Rolf Smith, Marian Andrzej Obojski, Thorsten Graf, Marc Michael Meinecke, Alexander Kirchner, Thanh Binh To și Matthias Koenig, pentru competența și disponibilitatea cu care ne-au ajutat să trecem peste toate obstacolele și să obținem rezultate originale și relevante timp de mai mult de zece ani.

Mulțumesc Comisiei Europene pentru finanțarea proiectului INTERSAFE-2, și Guvernului României pentru finanțarea proiectelor de tip PNII PERSENS, MULTISENS și SMARTCODRIVE, conduse de Prof. Sergiu Nedevschi, proiecte care mi-au oferit posibilitatea continuării activității de cercetare în domeniul viziunii computerizate, și mi-au oferit suficientă libertate pentru a putea proiecta noi modele ale lumii și noi tehnici de urmărire a parametrilor acestora. Aceste noi modele stau la baza rezultatelor prezentate în acest volum.

Mulțumesc de asemenea Guvernului României, care prin intermediul Unității Executive pentru Finanțarea Învățământului Superior, al Cercetării, Dezvoltării și Inovării (UEFISCDI), mi-a acordat finanțare pentru proiectul “DEEPPSENSE – Tehnici avansate de percepție a mediului folosind Deep Learning și estimatori probabilistici”, cod PN-III-P1-1.1-TE-2016-0440, proiect prin am din nou ocazia să reiau problema modelării și percepției mediului, și să aduc, împreună cu echipa mea, noi contribuții relevante.

Mulțumesc colegilor din cadrul colectivului IPPRC, foști și actuali, pentru ajutorul acordat în activitatea de cercetare, pentru competență, dedicație, și pentru acele momente de sclipire care au însemnat de multe ori găsirea în extremis a soluției și diferența dintre succes și eșec. Mulțumesc în special lui Tiberiu Marița, care prin tehnicile de calibrare a camerei a fost esențial pentru performanța sistemului de stereoviziune, lui Florin Oniga, care a realizat primii algoritmi de reconstrucție stereo ce au stat la baza procesărilor ulterioare, și care a realizat ulterior și procesarea punctelor 3D pentru a obține hărțile primare de înălțime și hărțile de ocupare primare, lui Ciprian Pocol, care a obținut primele cuboide din punctele 3D, și lui Cosmin Pantilie, care a perfecționat algoritmi de reconstrucție stereo densă, și a interfațat baza de date KITTI cu sistemul SCABOR, lucru care mi-a permis testarea algoritmilor pe această bază de date.

Mulțumesc de asemenea doctoranzilor mei Diana Borza și Răzvan Itu, care mi-au fost alături în multiple proiecte de cercetare, care au contribuit în mod decisiv la câștigarea competiției de proiecte PNIII-TE cu propunerea PN-III-P1-1.1-TE-2016-0440, și care vor contribui în continuare la succesul acestui proiect.