



FACULTATEA DE AUTOMATICĂ ȘI CALCULATOARE

*Ing. Radu Gabriel DĂNESCU*

# **TEZĂ DE DOCTORAT**

**(Rezumat)**

**Tehnici de viziune artificiala in timp real bazate pe  
estimatori probabilistici**

**Real-Time Computer Vision Techniques Based on  
Probabilistic Estimation**

**Conducător științific,  
Prof. dr. ing. Sergiu NEDEVSCI**

## **Comisia de evaluare a tezei de doctorat:**

- PREȘEDINTE: - Prof. dr. ing. *Tiberiu Leția* – Prodecan, Facultatea de Automatică și Calculatoare, Universitatea Tehnică din Cluj-Napoca;
- MEMBRI: - Prof. dr. ing. *Sergiu Nedevschi* – Conducător științific, Universitatea Tehnică din Cluj-Napoca;
- Prof. dr. ing. *Mircea Petrescu* – Referent, Universitatea „Politehnica” din București;
- Prof. dr. ing. *Nicolae Țăpuș* – Referent, Universitatea „Politehnica” din București;
- Prof. dr. ing. *Ioan Salomie* – Referent, Universitatea Tehnică din Cluj-Napoca.

## Cuprins

### 1. Introducere 4

### 2. Tehnici de urmărire bazate pe probabilități 7

2.1. Fundamentele teoretice ale tehnicilor de urmărire 7

2.2. Filtrul Kalman 9

2.2.1. Definirea problemei 9

2.2.2. Algoritmul de filtrare Kalman 10

2.3. Filtrul bazat pe particule 12

2.3.1. Definirea problemei 12

2.3.2. Filtrul – vedere de ansamblu 12

2.3.3. Re-eșantionare 13

2.3.4. Deplasare și difuzie 13

2.3.5. Măsură 14

2.3.6. Estimare 16

### 3. Studiu asupra tehnicilor de urmărire a drumului 16

3.1. Modelarea drumului și a benzilor de circulație 17

3.1.1. Reprezentarea statică clotoidală 17

3.1.2. Modelul clotoidal dinamic 19

3.2. Tehnici de extragere a trăsăturilor pentru urmărirea drumului 19

3.2.1. Extragerea trăsăturilor din imagini monoculare de intensitate 20

3.2.2. Extragerea trăsăturilor în imagini monoculare color 21

3.2.3. Extragerea trăsăturilor prin stereoviziune 23

3.3. Tehnici de estimare pentru urmărirea benzilor 24

3.3.1. Urmărirea benzilor prin filtrul Kalman 24

3.3.2. Estimarea drumului utilizând filtrul bazat pe particule 27

### 4. Senzorul bazat pe stereoviziune 29

4.1. Calibrarea camerelor 29

4.2. Reconstrucția stereo folosind geometria epipolară 30

4.3. Reconstrucția stereo densă pentru aplicații urbane 30

### 5. Soluții originale pentru urmărirea drumului bazate pe stereoviziune 31

5.1. Sistem de urmărire a drumului pentru autostrăzi și drumuri rurale, bazat pe filtrul Kalman 31

5.1.1. Modelarea benzii de circulație 31

5.1.2. Predicția 31

5.1.3. Procesul de măsură – detecția benzii de circulație 34

5.1.4. Detecția benzilor adiacente 38

5.1.5. Actualizarea stării benzilor 40

5.1.6. Teste și rezultate 40

5.1.7. Concluzii 41

5.2. Sistem de urmărire a drumurilor urbane, bazat pe stereoviziune și pe filtrul Kalman 42

5.2.1. Arhitectura soluției 42

5.2.2. Extragerea marcajelor 44

5.2.3. Potrivirea modelului benzilor prin drepte 45

5.2.4. Actualizarea parametrilor modelului benzii folosind rezultatele detecției liniare 49

5.2.5. Inițializarea și re-inițializarea procesului de urmărire 50

5.2.6. Detecția marginilor benzii fără constrângeri de model 50

5.2.7. Actualizarea stării benzii folosind rezultatele detecției fără constrângeri de model 51

5.2.8. Teste și rezultate 52

5.2.9. Concluzii 53

**5.3. Sistem de urmărire a benzilor în situații dificile folosind filtrul bazat pe particule 54**

- 5.3.1. Modelarea stării 54
- 5.3.2. Vedere de ansamblu asupra soluției 55
- 5.3.3. Predicția – re-eșantionare, deplasare, difuzie 55
- 5.3.4. Detecția unghiului de aplecare 56
- 5.3.5. Proiecția particulelor în spațiul măsurătorilor 58
- 5.3.6. Datele de măsură 58
- 5.3.7. Calcularea ponderilor pe baza măsurătorilor 59
- 5.3.8. Estimarea și validarea drumului 61
- 5.3.9. Abordarea schimbărilor de bandă 62
- 5.3.10. Teste și rezultate 63
- 5.3.11. Concluzii 65

*5.4. Integrarea sistemului 66*

**6. Concluzii 67****Bibliografie 71****Articole publicate în domeniul tezei 80****Citări independente relevante 83**

## 1. Introducere

Sistemele avansate de asistență a conducerii autovehiculelor (Advanced Driving Assistance Systems - ADAS) au ca scop creșterea autonomiei decizionale a vehiculelor, autonomie care va ajuta șoferul prin eliberarea acestuia de stresul asociat condusului pe distanțe lungi, și siguranța traficului, prin corectarea erorilor umane.

Acest domeniu este abordat de cercetători de mai bine de douăzeci de ani, iar primele rezultate au fost atât de promițătoare, încât s-a crezut că nu va trece mult timp și vor exista mașini care se vor conduce singure. Totuși, nici unul din sistemele care au fost dezvoltate nu avea o rată de succes de 100%, iar amenințarea problemelor legale legate de accidentele cauzate de defecțiuni ale sistemelor autonome a dus la o atitudine mai conservatoare din partea producătorilor. Acesta este motivul pentru care foarte multe sisteme cu rezultate promițătoare au fost până la urmă abandonate.

În ultima vreme punctul de vedere asupra sistemelor de asistență a conducerii autovehiculelor s-a schimbat, un indiciu fiind chiar numele. Acum douăzeci de ani, numele domeniului de cercetare era „conducere autonomă”, și toate eforturile erau concertate spre construirea unei mașini care se va conduce singură. Termenul nou, „asistență a conducerii”, este mult mai prudent. Sistemul nu exclude șoferul, acesta rămânând principalul responsabil pentru comportamentul autovehiculului, dar șoferul poate fi ajutat, mai ales în situații standard. Cu schimbarea numelui s-au schimbat și cerințele pentru sistemele senzoriale folosite. De la un sensor nu ne mai așteptăm să funcționeze în orice condiții, să ofere cât mai multe informații posibile, și eventual să fie suficient pentru a conduce singur mașina, în schimb ne așteptăm ca acest sensor să funcționeze cât mai robust în situații specifice. Domeniul de aplicații s-a restrâns, dar rata de succes așteptată este crescută.

Două probleme sunt centrale pentru orice sensor dedicat sistemelor de asistență a conducerii: urmărirea obstacolelor și urmărirea benzilor de circulație. Aceste două tipuri de informație formează o mare parte din mediul în care mașina evoluează. Banda de circulație ne spune unde trebuie să mergă autovehiculul, iar obstacolele ne indică unde este permis și unde nu este permis să mergă. Dacă vom combina aceste două mulțimi vom obține suficiente informații pentru sistemul de control, care va vira, accelera sau frâna.

Deoarece așteptările pentru performanța sistemelor au crescut, problema detecției obstacolelor a fost deferită în ultima vreme către senzorii activi. Acești senzori măsoară distanța până la un obiect prin măsurarea timpului necesar pentru o undă să parcurgă distanța până la obiect și înapoi. Unda poate fi lumină, în cazul senzorilor laser, sau undă electromagnetică, în cazul radarului. La început au fost îngrijorări cu privire la interferențele dintre undele diferitelor participanți la trafic, dar acum aceste îngrijorări par exagerate, și sistemele bazate pe senzorii activi sunt deja pe piață. Singurele motive pentru care acești senzori nu sunt folosiți sunt aplicabilitatea limitată a radarului, și costul prohibitiv al senzorului laser. Principala problemă de performanță a acestor senzori este că ei generează măsurători de tip punct, iar aceste măsurători sunt dificil de conectat în obiecte mai mari, chiar dacă măsurătorile sunt foarte precise. Pentru radar, principala dificultate este că necesită o suprafață metalică pentru a fi reflectat.

Un sistem de detecție a obstacolelor bazat doar pe senzori activi va avea o aplicabilitate limitată, gen regulator de distanță pentru autovehiculele de lux. Acesta este motivul pentru care dacă se dorește construirea unui sistem robust de detecție a obstacolelor, senzorii activi trebuie combinați cu senzori bazați pe vederea artificială. Vederea artificială permite detecția obiectului ca un întreg, chiar dacă precizia măsurătorii este mai mică, iar senzorul activ va asocia precizia lui obiectului detectat. Vederea artificială poate fi monoculară, oferind doar detecție, fără măsurarea distanțelor, sau binoculară (stereoviziune), oferind și o precizie de măsură rezonabilă pe lângă detecție. Totuși, este greu de crezut că un sistem de detecție bazat doar pe vederea artificială ar putea fi acceptat în industria auto din zilele noastre.

Care este situația cu detecția benzilor de circulație? Această parte a problemei nu este ușor de rezolvat cu senzori activi, chiar dacă există unii entuziaști care pretind acest lucru. Problema ar putea fi rezolvată dacă s-ar modifica normele de construcție a drumurilor, deoarece delimitatoarele benzilor sunt de obicei marcate pictate, care nu au o structură 3D diferită de suprafața drumului, deci ele nu vor putea fi detectate de radar, iar laserul va trebui să se bazeze pe măsurarea reflectivității suprafețelor. Deci, un fel de procesare a imaginilor. Astfel, orice senzor am folosi, trebuie să ne bazăm pe aspectele vizuale ale marcajelor pentru a putea detecta limitele benzilor de circulație, iar cea mai simplă abordare este să folosim vederea artificială, monoculară sau stereo.

Senzorii bazați pe stereoviziune oferă informații 3D împreună cu informațiile vizuale, devenind astfel cei mai complecși și cei mai compleți senzori pentru asistența conducerii autovehiculelor. Procesarea perechilor de imagini implică găsirea trăsăturilor corespondente între cele două imagini, o sarcină dificilă care necesită timp de procesare considerabil, și care nu este imună la apariția erorilor. Pentru a obține performanță de la un sistem stereo, trebuie depus efort pentru stabilirea unor tehnici precise de calibrare a camerei, bazate pe modele precise și suficient de generale ale camerei. Parametrii obținuți prin procesul de calibrare vor fi folosiți în procesul de rectificare a imaginilor și eliminare a distorsiunilor cauzate de lentile. Imaginile rectificate vor fi supuse procesului de căutare a corespondențelor, unde optimizări în vederea măririi vitezei și a acurateții rezultatelor sunt esențiale. Echipa de cercetători în domeniul procesării imaginilor din cadrul Universității Tehnice din Cluj-Napoca a acumulat mulți ani de experiență în domeniul stereoviziunii, îmbunătățind constant tehnicile de calibrare, rectificare, căutare a corespondențelor și reconstrucția informațiilor tridimensionale, precum și în domeniul algoritmilor de nivel înalt care folosesc datele 3D obținute prin stereo.

**Obiectivul principal** al activității de cercetare descrisă în această teză este dezvoltarea de soluții originale pentru urmărirea benzilor de circulație, în vederea asistenței conducerii autovehiculelor în multiple scenarii dificile, folosind avantajele oferite de un senzor bazat pe stereoviziune. Pe lângă folosirea informației stereo, o altă caracteristică definitorie a soluțiilor descrise este utilizarea metodelor probabilistice de urmărire. Aceste metode sunt bazate pe model, permit inferența în prezența incertitudinilor, și permit integrarea mai multor trăsături eterogene, obținute prin metode multiple de procesare a datelor disponibile.

Această teză este organizată în așa fel încât rezultatele originale sunt descrise după ce bazele științifice ale cercetării sunt clar prezentate cititorului. Primul capitol prezintă o introducere neexhaustivă în domeniul tehnicilor de urmărire probabilistice. Acest capitol descrie pe scurt conceptele teoretice, iar apoi face o descriere detaliată a celor mai populare soluții generice, filtrul Kalman și filtrul bazat pe particule, și variațiile acestora. Descrierea soluțiilor de

urmărire este mai puțin orientată spre teorie, fiind mai mult orientată spre aspectele practice, sperând astfel că cititorul va găsi în această lucrare o sursă de informații utile.

Al doilea capitol prezintă o trecere în revistă a celor mai folosite tehnici de urmărire a benzilor de circulație. Prin structura acestui capitol, cititorului îi sunt prezentate mai multe moduri de modelare a geometriei și a dinamicii drumului, mai multe moduri de a extrage trăsături delimitatoare, mai multe moduri de a potrivi un model al drumului la aceste trăsături, precum și alte raționamente care pot fi folosite în procesul de urmărire. Această trecere în revistă a fost orientată spre acoperirea tuturor aspectelor problemei urmăririi benzilor de circulație, din mai multe puncte de vedere, nu spre acoperirea tuturor autorilor care au adus contribuții relevante în domeniu. Tehnicile descrise în acest capitol pun bazele pentru contribuțiile originale.

Al treilea capitol prezintă tehnicile de stereoviziune care produc datele 3D și datele de tip imagine care sunt folosite apoi în algoritmi de urmărire a benzilor de circulație. Acest capitol prezintă pe scurt problema reconstrucție 3D, calibrarea camerelor, procesarea stereo densă și procesarea bazată pe muchii, adică toată munca esențială pe care echipa noastră de cercetători de la UT Cluj-Napoca a depus-o pentru ca algoritmi de nivel înalt, precum cei de urmărire a drumului, să poată lucra cu date robuste.

Al patrulea capitol prezintă contribuțiile originale ale acestei teze. În acest capitol sunt descrise trei tehnici de urmărire a drumului, dezvoltate pe baza filtrelor Kalman și a filtrelor pe bază de particule, pentru diferite tipuri de scenarii: autostradă și drumuri din afara localităților, drumuri urbane, și drumuri cu discontinuități. Toate aceste metode se bazează pe informația stereo, sub forma punctelor 3D în spațiu cartezian. Datele stereo permit dezvoltarea de algoritmi pentru detecția directă a profilului vertical al șoselei, și o mai bună selecția a trăsăturilor care delimitează drumul. De asemenea, parametrii de calibrare ai camerelor ne permit să folosim raționamente specifice spațiului 3D chiar atunci când procesăm simple imagini – un concept care influențează algoritmi în mai multe faze.

Sistemele de urmărire a drumului nu sunt doar simpli algoritmi, ele sunt soluții ingineresti complexe. Aceste sisteme combină algoritmi, modele și tehnici vechi și noi, cunoscute și originale, în noi construcții care oferă rezultate precise și robuste în scenarii dificile. Fiecare soluție aduce o serie de contribuții originale, care sunt scoase în evidență la sfârșitul fiecărui sub-capitol. Aceste contribuții pot fi sumarizate prin termenul de „urmărire a benzilor de circulație pe baza informațiilor oferite de stereoviziune”, deoarece ele sunt derivate în principal din specificul senzorului stereo. Originalitatea și relevanța acestor rezultate este dovedită de numărul mare de lucrări publicate, și de citările independente primite de aceste lucrări.

Problema urmăririi drumului este departe de a fi rezolvată complet, și este încă subiect de cercetare activă. Senzori diferiți, tipuri diferite de delimitatori, multiple modele pentru drum, multiple geometrii ale suprafeței drumului și multiple tipuri de suprafețe, acestea sunt tot atâtea motive pentru care va exista întotdeauna nevoie de rezultate mai bune. Sper ca rezultatele prezentate în această teză, și textul acestei teze, să se dovedească a fi un ajutor pentru cercetătorii care vor aborda în viitor acest interesant domeniu de cercetare.

## 2. Tehnici de urmărire bazate pe probabilități

### 2.1. Fundamentele teoretice ale tehnicilor de urmărire

Deși nu există o definiție universală, putem să considerăm procesul de urmărire ca fiind procesul de raționare asupra stării unei entități care evoluează în timp, pe baza unei serii de observații. În particular, urmărirea benzii de circulație poate fi definită ca fiind procesul de raționare asupra poziției și a geometriei benzii, dacă se dă o serie de mulțimi de trăsături derivate din procesarea imaginilor.

O introducere în domeniul urmăririi ca inferență probabilistică este dată în [Forsyth2003] și [Isard1998]. Pe baza acestor materiale, voi încerca să fac o scurtă prezentare a problemei teoretice.

Starea entității de urmărit, în cadrul  $i$ , este descrisă de o variabilă aleatoare  $\mathbf{X}_i$ . Astfel, în loc să avem o valoare definită pentru starea entității, vom avea un set de valori posibile. O funcție a densității de probabilitate ne va descrie care valori au șansa să fie mai apropiate de starea adevărată (care nu poate fi observată direct).

Măsurătoarea din cadrul  $i$  este descrisă de variabila aleatoare  $\mathbf{Y}_i$ . Prin aceasta înțelegem că mai multe indicii sunt disponibile, sau că avem o mulțime continuă de indicii, și vom asocia o funcție de densitate a probabilității cu această mulțime.

Scopul urmăririi ca inferență probabilistică este să evaluăm  $P(\mathbf{X}_i | \mathbf{Y}_0 = y_0, \dots, \mathbf{Y}_i = y_i)$ , adică să calculăm densitatea de probabilitate condițională a stării  $\mathbf{X}_i$  dându-se secvența de măsurători din cadrele trecute și prezente.

Deoarece procesul de urmărire trebuie să ofere rezultate în fiecare cadru, și deoarece un algoritm de urmărire trebuie să funcționeze în mod relativ uniform pentru o perioadă nelimitată de timp, procesul de estimare al  $P(\mathbf{X}_i | \mathbf{Y}_0 = y_0, \dots, \mathbf{Y}_i = y_i)$  trebuie să fie scris într-o manieră recursivă, pentru ca rezultatele din cadrul anterior să poată fi reutilizate în estimarea din prezent. Pentru a obține acest lucru, se introduc următoarele concepte:

#### *Model dinamic*

Un sistem dinamic bine înțeles evoluează în mod predictibil, supunându-se unui set de ecuații ale evoluției sale. Un sistem complet imprevizibil evoluează într-o manieră aleatoare, dar chiar și în acest caz valorile aleatoare pot fi limitate la un domeniu de valori, sau se supun unei distribuții de probabilitate. Majoritatea sistemelor reale evoluează parțial previzibil, și parțial aleator. Indiferent de gradul de predictibilitate, putem reprezenta modelul dinamic ca  $P(\mathbf{X}_i | \mathbf{X}_{i-1})$  - probabilitatea de a atinge o valoare a variabilei aleatoare  $\mathbf{X}_i$  dându-se starea anterioară  $\mathbf{X}_{i-1}$ .

Modelul dinamic descrie complet densitatea de probabilitate a stării curente, pe baza stărilor anterioare, datorită unei foarte importante presupuneri simplificatoare, anume că doar trecutul imediat contează.

$$P(\mathbf{X}_i | \mathbf{X}_1, \dots, \mathbf{X}_{i-1}) = P(\mathbf{X}_i | \mathbf{X}_{i-1}) \quad (2.1)$$

### *Predicția*

Măsurătorile din trecut și modelul dinamic ne permit să inferăm valorile de probabilitate pentru starea curentă înainte ca măsurătorile din cadrul curent să fie procesate. În mod formal, predicția se scrie ca  $P(\mathbf{X}_i | \mathbf{Y}_0 = y_0, \dots, \mathbf{Y}_{i-1} = y_{i-1})$  - probabilitatea condițională a stării curente dându-se secvența de măsurători din trecut. Dacă presupunem că doar trecutul imediat contează, valorile de probabilitate ale predicției pot fi calculate recursiv pe baza rezultatului trecut și a modelului dinamic:

$$P(\mathbf{X}_i | y_0, \dots, y_{i-1}) = \int P(\mathbf{X}_i | \mathbf{X}_{i-1})P(\mathbf{X}_{i-1} | y_0, \dots, y_{i-1})d\mathbf{X}_{i-1} \quad (2.2)$$

### *Modelul observațiilor și asocierea datelor*

În fiecare cadru (moment de observație)  $i$  pot exista mai multe măsurători disponibile, dar nu toate sunt la fel de utile. Dacă notăm cu  $y_i^r$  a  $r$ -lea măsurătoare din cadrul  $i$ , probabilitatea ca măsurătoarea să fie utilă este  $P(\mathbf{Y}_i = y_i^r | y_0, \dots, y_{i-1})$  - adică pe baza măsurătorilor anterioare se decide dacă măsurătoarea utilă curentă este  $y_i^r$ . Această probabilitate este calculată ca:

$$P(\mathbf{Y}_i = y_i^r | y_0, \dots, y_{i-1}) = \int P(\mathbf{Y}_i = y_i^r | \mathbf{X}_i, y_0, \dots, y_{i-1})P(\mathbf{X}_i | y_0, \dots, y_{i-1})d\mathbf{X}_i \quad (2.3)$$

Pentru a simplifica lucrurile, se presupune că fiecare măsurătoare este independentă condițional de celelalte măsurători:

$$P(\mathbf{Y}_i, \mathbf{Y}_j, \dots, \mathbf{Y}_k | \mathbf{X}_i) = P(\mathbf{Y}_i | \mathbf{X}_i)P(\mathbf{Y}_j, \dots, \mathbf{Y}_k | \mathbf{X}_i) \quad (2.4)$$

Astfel, probabilitatea ca o anumite măsurătoare să fie relevantă pentru starea obiectului este:

$$P(\mathbf{Y}_i = y_i^r | y_0, \dots, y_{i-1}) = \int P(\mathbf{Y}_i = y_i^r | \mathbf{X}_i)P(\mathbf{X}_i | y_0, \dots, y_{i-1})d\mathbf{X}_i \quad (2.5)$$

În ecuația de mai sus avem doi termeni care, combinați, dau probabilitatea ca  $y_i^r$  să fie o măsurătoare utilă. Al doilea termen este predicția, iar primul termen este o instanțiere a mai generalei  $P(\mathbf{Y}_i | \mathbf{X}_i)$  care descrie densitatea de probabilitate condițională a tuturor posibilelor valori ale măsurătorii, dându-se starea  $\mathbf{X}_i$ . Astfel, *modelul de observație*  $P(\mathbf{Y}_i | \mathbf{X}_i)$  leagă spațiul stărilor de spațiul măsurătorilor, definind procesul de observație, în același mod în care  $P(\mathbf{X}_i | \mathbf{X}_{i-1})$  definește procesul dinamic al evoluției stării în timp.

### *Actualizarea stării (corecția)*

Toți termenii necesari fiind acum definiți, se poate calcula  $P(\mathbf{X}_i | \mathbf{Y}_0 = y_0, \dots, \mathbf{Y}_i = y_i)$ , scopul procesului de urmărire. Acest lucru este obținut prin aplicarea regulii lui Bayes:



$$P(\mathbf{X}_i | y_0, \dots, y_i) = \frac{P(y_i | \mathbf{X}_i)P(\mathbf{X}_i | y_0, \dots, y_{i-1})}{\int P(y_i | \mathbf{X}_i)P(\mathbf{X}_i | y_0, \dots, y_{i-1})d\mathbf{X}_i} \quad (2.6)$$

Numitorul poate fi considerat ca o constantă (probabilitatea măsurătorii dându-se toate stările posibile)

$$P(\mathbf{X}_i | y_0, \dots, y_i) = K_i P(y_i | \mathbf{X}_i) P(\mathbf{X}_i | y_0, \dots, y_{i-1}) \quad (2.7)$$

Constanta se poate ignora complet, și relația devina una de proporționalitate.

$$P(\mathbf{X}_i | y_0, \dots, y_i) \propto P(y_i | \mathbf{X}_i) P(\mathbf{X}_i | y_0, \dots, y_{i-1}) \quad (2.8)$$

Ecuatiile procesului de urmărire ca inferență probabilistică sunt prea complexe pentru a putea fi folosite în forma generală. Mai mult, densitățile de probabilitate implicate sunt uneori imposibil de exprimat analitic, și de aceea sunt aproximate. Aproximarea lor înseamnă sau forțarea într-o formă analitică cunoscută, precum funcția Gaussiană, sau menținerea unei reprezentări numerice în toate fazele procesului de urmărire. Fiecare tip de aproximare duce la o metodă practică de urmărire, care va fi descrisă în secțiunile următoare.

## 2.2. Filtrul Kalman

### 2.2.1. Definirea problemei

Cea mai populară reprezentare a unei funcții de densitate a probabilității este forma Gaussiană. Pentru o variabilă multidimensională  $\mathbf{x}$ , valoarea densității probabilității este:

$$p(\mathbf{x}) = \frac{1}{\sqrt{(2\pi)^n |\mathbf{P}|}} e^{-\frac{(\mathbf{x}-\boldsymbol{\mu})^T \mathbf{P}^{-1} (\mathbf{x}-\boldsymbol{\mu})}{2}} \quad (2.9)$$

Astfel, fiecare densitate de probabilitate este descrisă de doi parametri, valoarea medie  $\boldsymbol{\mu}$  și matricea de covarianță  $\mathbf{P}$ .

Dacă se folosesc modele Gaussiene pentru funcția de probabilitate, este foarte avantajos dacă modelul dinamic (ecuațiile care transformă starea anterioară în starea curentă) și modelul de măsurare (care pune în legătură spațiul stărilor cu spațiul măsurătorilor) pot fi exprimate ca transformări liniare, pentru că astfel natura Gaussiană ar fi păstrată.

$$\mathbf{X}_i \sim N(\mathbf{F}_i \mathbf{X}_{i-1}, \mathbf{Q}_i) \quad (2.10)$$

$$\mathbf{Y}_i \sim N(\mathbf{H}_i \mathbf{X}_i, \mathbf{R}_i) \quad (2.11)$$

### 2.2.2. Algoritmul de filtrare Kalman

Cea mai bună soluție pentru urmărirea unui proces cu funcție de probabilitate Gaussiană este filtrul Kalman [Kalman1960]. Algoritmul este compus din următorii pași, care trebuie executați în ordinea specificată.

#### 1) Predicția

Predicția inferă starea din cadrul  $i$ , din informațiile din cadrul anterior  $i-1$  și din modelul dinamic. Modelul dinamic liniar este aplicat estimării anterioare, și se obține valoarea prezisă pentru vectorul de stare curent. Adicional, valori ale unor mărimi cunoscute pot forma un vector de intrare  $\mathbf{u}_i$  care poate contribui la predicție.

Pe lângă modelul dinamic, exprimat de transformarea liniară  $\mathbf{F}_i$ , și de modelul intrării pe care îl exprimăm ca transformarea liniară  $\mathbf{B}_i$ , există o incertitudine  $\mathbf{w}_i$ . Această incertitudine (zgomot) exprimă devierea unui sistem real față de modelul dinamic și de intrare, care nu pot ține cont de orice evoluție. Acest zgomot are media zero, deci nu va influența predicția, care este exprimată de următoarea ecuație:

$$\overline{\mathbf{X}}_i = \mathbf{F}_i \mathbf{X}_{i-1} + \mathbf{B}_i \mathbf{u}_i \quad (2.12)$$

Pentru a obține matricea de covarianță pentru predicție, vom aplica transformările modelului dinamic matricei de covarianță a stării anterioare, modelul de transformare a intrării pe matricea de covarianță a intrării, și vom adăuga matricea de covarianță a incertitudinii. Notăm cu  $\mathbf{T}_i$  matricea de covarianță a intrării, și cu  $\mathbf{Q}_i$  matricea de covarianță a incertitudinii tranziției. Atunci covarianța predicției este:

$$\overline{\mathbf{P}}_i = \mathbf{F}_i \mathbf{P}_{i-1} \mathbf{F}_i^T + \mathbf{B}_i \mathbf{T}_i \mathbf{B}_i^T + \mathbf{Q}_i \quad (2.13)$$

#### 2) Procesul de măsurare

Proces extern filtrului Kalman, măsurătoarea are ca rezultat unul sau mai mulți vectori de măsură  $\mathbf{Y}_i^k$ , fiecare cu o matrice de covarianță  $\mathbf{R}_i^k$ , care codifică eroarea de măsurare estimată (imprecizia sensorului). Relația dintre vectorul de stare și vectorul de măsură este modelul de măsurare, iar dacă acesta este o transformare liniară aceasta este descrisă de matricea  $\mathbf{H}_i$ . Folosind acest model, obținem predicția măsurătorii,  $\overline{\mathbf{Y}}_i$ .

$$\overline{\mathbf{Y}}_i = \mathbf{H}_i \overline{\mathbf{X}}_i \quad (2.14)$$

Matricea de covarianță pe care o vom asocia lui  $\overline{\mathbf{Y}}_i$  va fi notată  $\mathbf{S}_i$ .

$$\mathbf{S}_i = \mathbf{H}_i \mathbf{P}_i \mathbf{H}_i^T + \mathbf{R}_i \quad (2.15)$$

Matricea  $\mathbf{S}_i$  nu este matricea de covarianță a măsurătorii prezise, ci matricea de covarianță a diferenței dintre măsurătoarea prezisă și o posibilă măsurătoare reală (matricea de covarianță a *inovării*, sau a *rezidualului*) – adică exact matricea necesară pentru a defini o zonă de căutare în jurul măsurătorii prezise  $\overline{\mathbf{Y}}_i$ .

### 3) Asocierea datelor

Filtrul Kalman este foarte vulnerabil la asocierea datelor (asocierea măsurătorilor) [Bar-Shalom1988], din cauza naturii unimodale a funcției de probabilitate în fiecare din fazele de lucru ale filtrului. Acest lucru înseamnă că vectorul de stare, odată deplasat spre un indiciu fals, va deveni criteriul de selecție pentru măsurătorile viitoare, asta însemnând mai multe date greșite incluse în estimare, până la devierea totală de la țintă.

Singura măsură obiectivă a utilității măsurătorii  $\mathbf{Y}_i^k$  este verosimilitatea ei, dându-se starea unui obiect urmărit. Această verosimilitate este dată de funcția de probabilitate Gaussiană, centrată în predicția măsurătorii  $\overline{\mathbf{Y}}_i$ , și având matricea de covarianță  $\mathbf{S}_i$ .

$$p(\mathbf{Y}_i^k) = \frac{1}{\sqrt{(2\pi)^n |\mathbf{S}_i|}} e^{-\frac{(\mathbf{Y}_i^k - \overline{\mathbf{Y}}_i)^T \mathbf{S}_i^{-1} (\mathbf{Y}_i^k - \overline{\mathbf{Y}}_i)}{2}} \quad (2.16)$$

### 4) Actualizare (corecție)

În acest moment toate datele necesare sunt disponibile, și se va calcula noul vector de stare  $\mathbf{X}_i$  și matricea sa de covarianță  $\mathbf{P}_i$ .

Prima dată se calculează matricea de amplificare Kalman,  $\mathbf{K}_i$ :

$$\mathbf{K}_i = \overline{\mathbf{P}}_i \mathbf{H}_i^T (\mathbf{H}_i \overline{\mathbf{P}}_i \mathbf{H}_i^T + \mathbf{R}_i)^{-1} \quad (2.17)$$

Ecuția este echivalentă cu

$$\mathbf{K}_i = \overline{\mathbf{P}}_i \mathbf{H}_i^T \mathbf{S}_i^{-1} \quad (2.18)$$

Noul vector de stare se calculează astfel:

$$\mathbf{X}_i = \overline{\mathbf{X}}_i + \mathbf{K}_i (\mathbf{Y}_i - \overline{\mathbf{Y}}_i) \quad (2.19)$$

Pasul final este calcularea matricei de covarianță  $\mathbf{P}_i$ . Majoritatea documentațiilor disponibile dau ecuația (2.20) pentru calculul  $\mathbf{P}_i$ .

$$\mathbf{P}_i = (\mathbf{I} - \mathbf{K}_i \mathbf{H}_i) \overline{\mathbf{P}}_i \quad (2.20)$$

## 2.3. Filtrul bazat pe particule

Principala problemă a oricărei variante a filtrului Kalman este presupunerea că starea și măsurătorile au funcții de densitate a probabilității de tip Gaussian. Această presupunere face ca filtrele Kalman să fie incapabile de a urmări mai multe ipoteze independente, care formează mai multe maxime în funcția de probabilitate.

### 2.3.1. Definirea problemei

O abordare practică pentru urmărirea unei funcții generale de probabilitate este filtrul de particule, a cărui adaptare pentru urmărirea bazată pe procesare de imagini este descrisă în [Isard1998] sub numele de CONDENSATION (CONDitional DENSity PropagATIOn). În loc să se încerce aproximarea funcțiilor prin forme analitice, această soluție folosește  $N$  valori discrete numite „eșantioane” sau „particule”. În fiecare moment  $i$ , o particulă  $k$  este definită de o valoare  $\mathbf{x}_i^k$  și o pondere  $\pi_i^k$ .

$$p(\mathbf{x}_i) \approx \{\mathbf{x}_i^k, \pi_i^k, k = 1 \dots N\} \quad (2.21)$$

Suma tuturor ponderilor este 1.

$$\sum_{k=1}^N \pi_i^k = 1 \quad (2.22)$$

Problema urmării devine problema evaluării valorilor  $\mathbf{x}_i^k$  și a ponderilor  $\pi_i^k$  la fiecare moment (cadru, ciclu de măsură)  $i$ , dându-se un model dinamic și o funcție de probabilitate a măsurătorii.

În scopul optimizării algoritmului, se adaugă la fiecare particulă un parametru  $c_i^k$ , astfel că o particulă devine definită ca  $\{\mathbf{x}_i^k, \pi_i^k, c_i^k, k = 1 \dots N\}$ . Acest parametru este definit ca suma ponderilor particulelor de la 1 la  $k$  (este de fapt o histogramă cumulativă). Scopul acestui parametru este descris în cele ce urmează.

$$c_i^k = \sum_{n=1}^k \pi_i^n \quad (2.23)$$

### 2.3.2. Filtrul – vedere de ansamblu

Fiecare iterație a algoritmului CONDENSATION are ca scop evaluarea unei noi mulțimi de particule,  $\{\mathbf{x}_i^k, \pi_i^k, c_i^k, k = 1 \dots N\}$  pe baza mulțimii anterioare,  $\{\mathbf{x}_{i-1}^k, \pi_{i-1}^k, c_{i-1}^k, k = 1 \dots N\}$ , a modelului dinamic și a măsurătorilor. O vedere de ansamblu este figura următoare.

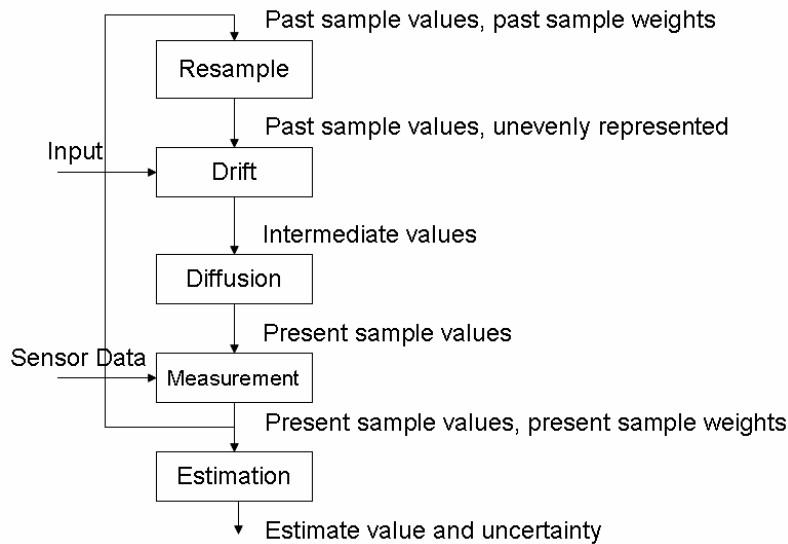


Fig. 2.1. Vedere de ansamblu a algoritmului CONDENSATION

Blocurile principale sunt:

*Re-eșantionare (Resample)* – procesul care transformă mulțimea de particule cu ponderi diferite ce descrie funcția de probabilitate anterioară într-un set echivalent de particule cu ponderi egale.

*Deplasare (Drift)* – modelul dinamic este aplicat particulelor re-eșantionate.

*Difuzie (Diffusion)* – o valoare aleatoare este aplicată valorii fiecărei particule, pentru a se modela incertitudinea tranziției stărilor.

*Măsură (Measurement)* – fiecare particulă este comparată cu informațiile obținute prin măsurători, și se calculează ponderea ei pe baza calității potrivirii.

*Estimare (Estimation)* – se calculează o stare medie a sistemului urmărit, pe baza combinării valorilor particulelor prin medie ponderată.

### 2.3.3. Re-eșantionare

O mulțime de particule cu ponderi diferite este transformată într-o nouă mulțime, cu ponderi egale dar concentrații diferite ale valorilor particulelor în spațiul stărilor. Cele două mulțimi aproximează aceeași funcție de probabilitate.

Pentru a se obține eșantioane cu pondere egală algoritmul va face  $N$  extrageri aleatoare din funcția de probabilitate descrisă de eșantioanele ponderate, prin procesul arătat în [Bock1998].

### 2.3.4. Deplasare și difuzie

Acești doi pași pot fi grupați sub termenul *predicție*. În formă generală, predicția este obținută prin eșantionarea funcției de densitate care redă modelul dinamic,  $p(\mathbf{x}_i | \mathbf{x}_{i-1} = \mathbf{x}_{i-1}^k)$ . O abordare mai realistă este să presupunem că starea prezentă este derivată din starea anterioară în parte printr-un proces deterministic, descris de o funcție de transformare, și în parte printr-un factor aleator.

Deplasarea deterministă este similară cu predicția stării din filtrul Kalman, dar în loc să se aplice ecuațiile tranziției stărilor unui singur vector mediu, ele se aplică fiecărei valori eșantion  $\mathbf{x}_{i-1}^k$ . În mod similar cu filtrul Kalman, putem avea valori de intrare  $\mathbf{u}_i$  care afectează predicția.

$$\overline{\mathbf{x}}_i^k = f_i(\overline{\mathbf{x}}_{i-1}^k, \mathbf{u}_i) \quad (2.24)$$

Dacă tranziția stărilor e liniară, putem utiliza ecuația

$$\overline{\mathbf{x}}_i^k = \mathbf{F}_i \overline{\mathbf{x}}_{i-1}^k + \mathbf{B}_i \mathbf{u}_i \quad (2.25)$$

Deplasamentul deterministic este urmat de o difuzie stohastică (aleatoare), unde fiecare valoare  $\overline{\mathbf{x}}_i^k$  rezultată din aplicarea ecuațiilor modelului dinamic primește o alterație aleatoare.

$$\mathbf{x}_i^k = \overline{\mathbf{x}}_i^k + \mathbf{w}_i^k \quad (2.26)$$

Vectorul  $\mathbf{w}_i^k$  este un zgomot aleator extras dintr-o distribuție potrivită cu imprevizibilitatea tranzițiilor sistemului urmărit. Dacă acest zgomot este Gaussian, el este descris de matricea de covarianță  $\mathbf{Q}_i$ .

După ce ecuațiile difuziei aleatoare (ecuația 2.26) sunt aplicate particulelor re-eșantionate și deplasate, valorile obținute  $\mathbf{x}_i^k$  devin valorile finale pentru pasul curent, și vor fi notate ca atare, fără semnul de predicție deasupra lor. În acest moment, cititorul nu mai trebuie să facă distincția între fostele și actualele valori, deoarece în fiecare pas doar un set de valori este folosit. După re-eșantionare, singurele valori care există sunt cele re-eșantionate. După ce predicția este aplicată, singurele valori existente sunt cele prezise. Acest lucru simplifică foarte mult implementarea – sistemul poate menține doar un singur șir persistent de valori, care vor fi supuse la multiple transformări, două șiruri fiind necesare doar în faza de re-eșantionare.

Valoarea particulelor fiind deja calculată, urmează calcularea ponderilor noi, folosind datele de măsură.

### 2.3.5. Măsură

Pasul final al algoritmului este măsurarea/actualizare. În formularea generală a problemei urmăririi ca inferență probabilistică, actualizarea înseamnă aplicarea regulii lui Bayes pentru obținerea probabilităților posterioare.

$$p(\mathbf{x}_i | \mathbf{y}_0, \dots, \mathbf{y}_i) \propto p(\mathbf{y}_i | \mathbf{x}_i) p(\mathbf{x}_i | \mathbf{y}_0, \dots, \mathbf{y}_{i-1}) \quad (2.27)$$

Densitatea de probabilitate „a priori”, adică înaintea măsurătorii, este acum codificată în distribuția valorii particulelor fără pondere  $\mathbf{x}_i^k$  în spațiul stărilor. Probabilitatea posterioară, este obținută prin simpla ponderare a acestor particule.

$$\pi_i^k = p(\mathbf{y}_i | \mathbf{x}_i = \mathbf{x}_i^k) \quad (2.28)$$

$p(\mathbf{y}_i | \mathbf{x}_i = \mathbf{x}_i^k)$  este verosimilitatea observației  $\mathbf{y}_i$  presupunându-se că starea curentă este descrisă de  $\mathbf{x}_i^k$ .

Metoda practică de calcul a  $p(\mathbf{y}_i | \mathbf{x}_i = \mathbf{x}_i^k)$  consistă din execuția următorilor pași:

*a) Proiecția valorii particulei în spațiul măsurătorilor*

Acest pas este echivalent cu predicția măsurătorii din filtrul Kalman. Valoarea particulei va fi transformată într-un vector  $\overline{\mathbf{y}}_i^k$  folosind o funcție de măsură  $h_i$ . Natura acestei funcții nu are importanță pentru algoritm, ea poate fi tratată ca un proces închis (black box).

$$\overline{\mathbf{y}}_i^k = h_i(\mathbf{x}_i^k) \quad (2.29)$$

*b) Analiza datelor senzoriale și extragerea măsurătorilor*

Pentru analiza datelor senzoriale, se pot folosi algoritmi complecși, care vor genera măsurători discrete similare cu vectorul prezis  $\overline{\mathbf{y}}_i^k$ , sau se pot folosi algoritmi simpli, precum detectorii de muchie, și o funcție de potrivire care să compare vectorul prezis cu datele senzoriale.

*c) Potrivirea măsurătorilor prezise la datele senzoriale*

Dacă se folosesc algoritmi complecși, și ei vor produce un vector de măsură  $\mathbf{y}_i$ , fiecare particulă va fi ponderată folosind distanța dintre măsura prezisă  $\overline{\mathbf{y}}_i^k$  și măsura reală. Dacă modelul erorii măsurătorii este Gaussian, se poate aplica ecuația următoare:

$$\pi_i^k = \frac{1}{\sqrt{(2\pi)^m |\mathbf{R}_i|}} e^{-\frac{(\overline{\mathbf{y}}_i^k - \mathbf{y}_i)^T \mathbf{R}_i^{-1} (\overline{\mathbf{y}}_i^k - \mathbf{y}_i)}{2}} \quad (2.30)$$

În ecuația anterioară,  $m$  este dimensiunea vectorului de măsură, iar  $\mathbf{R}_i$  este covarianța erorii de măsură, aceeași ca în filtrul Kalman.

Problema este că folosind algoritmi complecși pentru măsură, pierdem unul din cele mai importante avantaje ale filtrului de particule. Adevărata putere a filtrului de particule, pe lângă posibilitatea de a urmări densități de probabilitate non-Gaussiene, este că poate utiliza măsurări foarte simple. În loc să se folosească algoritmi de detecție pentru a recunoaște o măsurătoare dintr-un set de date primare, se poate utiliza o funcție de potrivire  $d$  care va evalua direct cât de bine se potrivește o particulă la o mulțime de date primare  $S$ . Putem defini o distanță pentru fiecare particulă,  $k$ ,  $D_i^k$ , fără a fi nevoie de un vector de măsură  $\mathbf{y}_i$  (măsura va exista doar ca concept teoretic, nu ca vector).

$$D_i^k = d(\overline{\mathbf{y}}_i^k, S_i) \quad (2.31)$$

Dacă distanța dintre particulă și datele de măsură este unidimensională, putem folosi o ecuație mult mai simplă pentru calculul ponderii, ecuația 2.32.

$$\pi_i^k = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(D_i^k)^2}{2\sigma^2}} \quad (2.32)$$

Valoarea lui  $\sigma$  este caracteristică algoritmului de potrivire.

Dacă procesul de măsurare folosește date din  $M$  surse diferite, se calculează ponderile pentru fiecare sursă, și se combină prin înmulțire.

### 2.3.6. Estimare

Deși informația despre sistemul care este urmărit este conținută complet în valorile particulelor și în ponderile acestora, uneori este necesar să avem o singură valoare, cea mai probabilă. De exemplu, când se urmărește poziția unui obiect este util să avem o valoare care este cel mai probabil să fie bună, decât mai multe valori și mai multe ponderi. Acest lucru înseamnă că trebuie să facem o estimare, prin medierea ponderată a valorilor particulelor.

$$E(\mathbf{x}_i) = \sum_{k=1}^N \mathbf{x}_i^k \pi_i^k \quad (2.33)$$

Uneori este necesar să se cunoască precizia estimării, iar o măsură a preciziei este matricea de covarianță, pe care o vom nota cu  $\mathbf{P}_i$ , pentru a avea aceleași notații ca și la filtrul Kalman.

$$\mathbf{P}_i = \sum_{k=1}^N \pi_i^k (\mathbf{x}_i^k - E(\mathbf{x}_i))(\mathbf{x}_i^k - E(\mathbf{x}_i))^T \quad (2.34)$$

Ecuațiile 2.33 și 2.34 nu sunt potrivite pentru orice situație, deoarece funcția de probabilitate poate fi multimodală, urmărind mai multe ipoteze simultan. Dacă majoritatea ipotezelor sunt de fapt zgomot, insuficient validat de măsurători, sistemul poate să elimine particulele cu ponderi reduse din ecuațiile de estimare [Franke2007].

Dacă sistemul se așteaptă la posibilitatea urmăririi ipotezelor multiple, particulele pot fi grupate pe criterii de vecinătate, și fiecare grup va produce o estimare diferită [Chan2007]. O metodă simplă de grupare este Modified Basic Sequential Algorithm Scheme (MBSAS), descrisă în [Theodoridis2006].

## 3. Studiu asupra tehnicilor de urmărire a drumului

Procesul de urmărire a drumului (sau a benzii de circulație) poate fi împărțit în mai mulți pași, fiecare pas putând fi realizat în mai multe feluri. Acești pași sunt:

1. Găsirea unui model matematic adecvat.
2. Extragerea trăsăturilor care delimitează drumul sau banda, prin procesarea datelor senzoriale (extragerea datelor de măsură).
3. Estimarea (urmărirea) parametrilor modelului folosind trăsăturile extrase.



#### 4. Raționamente adiționale.

Primul pas este modelarea drumului. Modelarea trebuie făcută din trei puncte de vedere:

- **Modelul 3D staționar (geometric):** acest model descrie aspectul drumului în spațiul 3D.
- **Modelul 3D dinamic:** acest model cuprinde ecuațiile care descriu evoluția parametrilor modelului staționar în timp. Acest model permite urmărirea drumului prin facilitatea predicției.
- **Modelul de măsură (dectecție):** acest model poate fi identic cu modelul staționar 3D, sau poate fi complet diferit. De exemplu, dacă detecția se realizează în spațiul imagine, trebuie folosit ca model de măsură proiecția modelului 3D în spațiul imagine.

Modelul static și modelul dinamic vor fi descrise în capitolul următor, iar modelul de detecție va fi descris împreună cu tehnicile de măsură.

După ce modelul de detecție a fost ales, următorul pas este extragerea trăsăturilor care vor fi folosite ca măsurători pentru procesul de urmărire. Căutarea trăsăturilor poate fi făcută în spațiul imagine, sau pe date 3D.

Potrivirea modelului la trăsături este elementul central al procesului de estimare-urmărire. Constrângerile modelului se compară cu constrângerile realității, reprezentate de trăsăturile extrase. Un model bine ales ne permite să evităm piste false.

### 3.1. Modelarea drumului și a benzilor de circulație

Modelul static 3D consacrat pentru drumuri este clotoida. Vom analiza cel mai complex model clotoidal, prezentat în [Goldbeck1999], și vom încerca să înțelegem proveniența lui și de ce este el potrivit pentru a reprezenta geometria drumului. Vom analiza apoi dinamica acestui model, apoi vom trece în revistă alte lucrări, pentru a vedea cum acest model este simplificat sau complicat pentru a se potrivi cu diferite scopuri.

#### 3.1.1. Reprezentarea statică clotoidală

Prin modelarea statică înțelegem definirea unor ecuații care dau coordonatele  $(X, Y)$  a unui punct de pe un delimitator al benzii de circulație, dacă se dă distanța  $Z$ . Poziția laterală  $X$ , și înălțimea  $Y$ , a unui punct de pe marginea unei benzi sunt afectate de geometria drumului, și de poziția autovehiculului din care se face observația față de drum. Vom defini un sistem de coordonate pentru drum, și un sistem de coordonate propriu vehiculului.

Poziția autovehiculului în sistemul de referință al drumului este dată de vectorul de translație  $\mathbf{T}_C$  și de vectorul de rotație  $\mathbf{r}_C = (\alpha, \psi, \gamma)$  – care va da matricea de rotație  $\mathbf{R}_C$ . Sistemul de coordonate al vehiculului poate fi rotit în jurul axelor  $X, Y, Z$  cu unghiurile:

- $\alpha$  – unghiul de aplecare (tangaj, pitch)
- $\psi$  – unghiul de orientare (azimut, yaw), unghiul dintre axa longitudinală a mașinii și tangenta la axa drumului. Acest unghi dă direcția vehiculului față de drum.
- $\gamma$  – unghiul de înclinare laterală (de ruliu).

Este o practică frecventă ca originea sistemului de coordonate a drumului să fie considerată ca plasată în mijlocul drumului, lângă vehicul, astfel ca vectorul de translație să conțină doar un deplasament lateral:  $\mathbf{T}_C = (X_{CW}, 0, 0)$ .

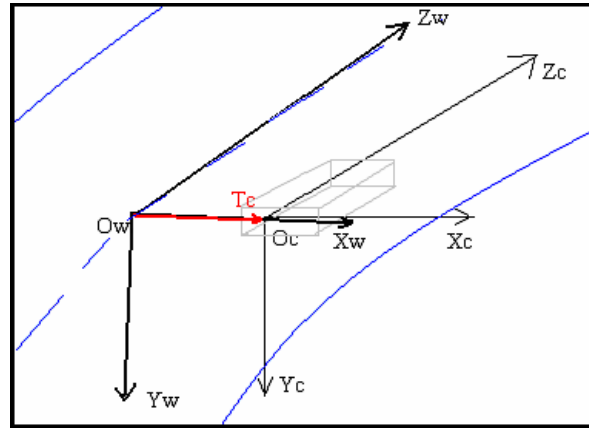


Fig. 3.1. Sistemul de coordonate al drumului și cel al vehiculului.

Un punct având poziția în sistemul drumului specificată de vectorul  $\mathbf{X}_W$  va avea în sistemul de coordonate al vehiculului poziția dată de vectorul  $\mathbf{X}_C$ :

$$\mathbf{X}_c = \mathbf{R}_c(\mathbf{X}_w - \mathbf{T}_c) \quad (3.1)$$

Pentru reprezentarea drumului, avem nevoie de geometria acestuia, sub forma profilului orizontal și vertical. Drumul va fi reprezentat în sistemul propriu de referință, iar profilele sunt clotoide de gradul 1.

Geometria drumului se va exprima prin două aproximări ale clotoidei cu curbe de gradul 3:

$$\begin{aligned} X &= -X_{CW} - \alpha_0 Z + c_{0,h} \frac{Z^2}{2} + c_{1,h} \frac{Z^3}{6} \\ Y &= \alpha Z + c_{0,v} \frac{Z^2}{2} + c_{1,v} \frac{Z^3}{6} \end{aligned} \quad (3.2)$$

Ecuțiile delimitatorilor sunt:

$$\begin{aligned} X_{left} &= -\frac{W}{2} - X_{CW} - \alpha_0 Z + c_{0,h} \frac{Z^2}{2} + c_{1,h} \frac{Z^3}{6} \\ X_{right} &= \frac{W}{2} - X_{CW} - \alpha_0 Z + c_{0,h} \frac{Z^2}{2} + c_{1,h} \frac{Z^3}{6} \end{aligned} \quad (3.3)$$

Lățimea benzii este presupusă fixă de majoritatea cercetătorilor, și așa o vom considera și noi pentru majoritatea aplicațiilor. În capitolul 5 vom analiza un model cu lățime variabilă. Astfel, valorile necesare pentru descrierea caracteristicilor drumului și a poziției vehiculului propriu pe drum sunt:

- Unghiul de aplecare  $\alpha$ , orientare  $\psi$  și înclinare  $\gamma$
- $X_{CW}$ , deplasamentul lateral față de centrul drumului.
- $W$ , lățimea drumului (a benzii)
- Curbură orizontală  $c_{h,0}$ , și variația curburii orizontale  $c_{h,1}$

- Curbura verticală  $c_{v,0}$ , și variația curburii verticale  $c_{v,1}$

### 3.1.2. Modelul clotoidal dinamic

Se dorește exprimarea evoluției vectorului de parametri ai clotoidei  $\mathbf{X}=(W, c_{h,0}, c_{h,1}, c_{v,0}, c_{v,1}, X_{CW}, \alpha, \gamma, \psi)^T$  în timp. Pentru aceasta sunt necesari următorii parametri: intervalul de timp dintre măsurători,  $\Delta t_i$  și viteza vehiculului  $v_i$ . Știind viteza și timpul, putem calcula distanța parcursă între două cadre,  $s_i = v_i \Delta t_i$ . Un alt parametru care poate fi folosit este curbura traiectoriei vehiculului (curbura de viraj),  $e_i$ . Evoluția vectorului de stare în timp poate fi scrisă sub formă matricială ca

$$\mathbf{X}_{i+1} = \mathbf{F}_i \mathbf{X}_i + \mathbf{B}_i \mathbf{u}_i \quad (3.4)$$

$$\mathbf{u}_i = e_i$$

$$\mathbf{F}_i = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & v_i \Delta t_i & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & v_i \Delta t_i & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & -\frac{(v_i \Delta t_i)^2}{2} & -\frac{(v_i \Delta t_i)^3}{6} & 0 & 0 & 1 & 0 & 0 & v_i \Delta t_i \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & -v_i \Delta t_i & -\frac{(v_i \Delta t_i)^2}{2} & 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (3.5)$$

$$\mathbf{B}_i = \begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \\ 0 \\ \frac{(v_i \Delta t_i)^2}{2} \\ 0 \\ 0 \\ v_i \Delta t_i \end{bmatrix} \quad (3.6)$$

## 3.2. Tehnici de extragere a trăsăturilor pentru urmărirea drumului

În acest capitol sunt descrise tehnicile de procesare a datelor primare. Aici vom vedea algoritmi de procesare a imaginilor și a altor date senzoriale pentru a identifica cele mai relevante indicii delimitatoare.

### 3.2.1. Extragerea trăsăturilor din imagini monoculare de intensitate

#### *Maximul local al gradientului*

Soluțiile prezentate în [Aufreere2000], [Aufreere2001] și alte articole conexe arată că se poate face urmărirea robustă a drumului folosind trăsături foarte simple, și compensând cu tehnici elaborate de potrivire a modelului. Trăsăturile selectate sunt maximele locale ale gradientului imaginii dintr-o regiune de căutare. Pentru fiecare linie orizontală din zona de căutare se selectează punctul cu cea mai mare valoare a modulului gradientului.

#### *Modulul și orientarea gradientului*

Poate impropriu numit trăsătură, gradientul imaginilor poate fi folosit direct pentru potrivirea modelului, așa cum se arată în [Kluge1995], [Kreucher1998] și în alte lucrări. Gradientul este derivata direcțională de ordinul întâi, cu componentele modul și orientare. Ambele aceste componente se pot folosi pentru potrivire de modele.

#### *Tranziții Întuneric-Lumină-Întuneric antiparalele*

Marcajul rutier clasic este văzut ca o bandă luminoasă pe un fundal mai întunecat. Acesta este motivul pentru care multe soluții, printre care cele prezentate în [Goldbeck1998] și [Goldbeck1999] folosesc detecția tranzițiilor întuneric-lumină-întuneric ca detectorul primar de trăsături delimitatoare. Aceste tranziții se materializează ca valori ale gradientului de modul egal dar de semn opus.




Fig. 3.2. Gradientul orizontal pentru un marcaj, și tranziția DLD codificată de gradient.

#### *Detecția muchiilor*

Deși poate ne-am gândi că detecția muchiilor, nu doar calculul gradientului, ar trebui să fie prima alegere pentru estimarea benzilor, aceasta nu este atât de folosită, deoarece un detector bun de muchii necesită timp de procesare. Detectorul de muchii Canny este alegerea făcută în [Yu1995], unde muchiile sunt folosite ca intrare pentru un algoritm de tip transformată Hough, și, mai recent, în soluția descrisă de [Aufreere2004].

#### *Trăsături din domeniul de frecvențe*

[Kreucher1999] folosește ca trăsături coeficienți obținuți prin transformata cosinus discretă. Imaginea este împărțită în blocuri de 8 pixeli, și DCT se aplică pe fiecare bloc, extrăgându-se 64 de coeficienți, din care se aleg 12 elemente, corespunzând cu orientările predominant diagonale. „Imaginea” obținută nu este binarizată, ci este utilizată ca atare într-o tehnică de potrivire a modelului bazată pe probabilități.

#### *Selecția trăsăturilor prin filtre configurabile*

Algoritmii descriși în [McCall2004] folosesc trăsăturile obținute prin folosirea filtrelor configurabile (orientabile) bazate pe derivata a doua a unui Gaussian bidimensional. Filtrul este o combinație de trei filtre primare, orizontal, diagonal și vertical. Prin aplicarea acestor filtre, se pot pune în evidență trăsături la un unghi specificat, sau prin analiza răspunsului la aplicarea filtrelor primare se poate estima unghiul trăsăturilor necunoscute. Evidențierea marcajelor de circulație se face prin utilizarea predicției și luarea în considerare a trăsăturilor cu unghiul corespunzător.

#### *Detecția trăsăturilor pe baza transformatei perspectivă inversă*

O metodă complexă de extragere a trăsăturilor este prezentată în [Broggi1998] și [Broggi1995]. Ideea principală este de a transforma imaginea prin aplicarea transformatei IPM într-o imagine echivalentă văzută de la înălțime. În acest fel marcajele vor avea aceeași lățime în toată imaginea, nemaifiind afectate de efectul de perspectivă.

După aplicarea IPM, se efectuează următorii pași:

- Filtrarea imaginii, selecția pixelilor care au o intensitate mai mare decât vecinii lor.
- Potențarea imaginii filtrate: fiecare pixel care este selectat în pasul anterior va fi înlocuit cu intensitatea unui vecin cu intensitate maximă.
- Binarizare adaptativă, cu un prag calculat în vecinătatea fiecărui pixel.



Fig. 3.3. De la IPM la trăsăturile marcaj.

### **3.2.2. Extragerea trăsăturilor în imagini monoculare color**

Folosirea imaginilor color pentru detecția drumului este destul de limitată, din cauza cantității crescute a datelor de procesat, iar în situații de autostradă nu prea există culoare pe drum. Totuși, culoarea este binevenită în situația drumurilor de țară, unde e posibil să nu existe trăsături tip muchie foarte pronunțate, iar intensitatea ierbii să fie similară cu intensitatea asfaltului. Problema detecției drumului de țară este de obicei o problemă de segmentare, iar informația color este foarte potrivită pentru această sarcină.

#### *Segmentarea în spațiul color RGB folosind distanța Mahalanobis*

O metodă de segmentare numită UNSCARF (Unsupervised Clustering Applied to Road Following) este prezentată în [Crisman1991].

Un vector de trăsături  $\mathbf{x} = [\text{red, green, blue, row, column}]$  este atașat fiecărui pixel. Inițial, fiecare pixel primește o clasă arbitrară. O clasă  $i$  este definită de vectorul mede a vectorilor  $\mathbf{x}$  ai pixelilor clasei, numit  $\mathbf{m}_i$ , și de matricea de covarianță  $\mathbf{C}_i$ . Clasa pixelului poate fi

schimbată la altă clasă  $i$  dacă distanța Mahalanobis de la vectorul  $\mathbf{x}$  al pixelului și clasa  $i$  este mai mică decât distanța de la pixel la clasa anterioară  $j$ . Această distanță este:

$$\alpha_i = (\mathbf{x} - \mathbf{m}_i)^T \mathbf{C}_i^{-1} (\mathbf{x} - \mathbf{m}_i) \quad (3.7)$$

Clasele cu puțini pixeli sunt eliminate din set printr-un algoritm de dilatare și contracție.

#### *Folosirea distanței Fisher și a unor presupuneri despre natura culorilor*

Metodele descrise în [Chern2004] folosesc o altă metrică pentru segmentarea drumurilor de țară. Pixelii sunt grupați în clase pe baza distanței Fisher, definită prin următoarele ecuații:

$$\begin{aligned} \mu &= \frac{1}{n} \sum f(x, y) \\ v &= \frac{1}{n} \sum (f(x, y) - \mu)^2 = \frac{1}{n} \sum f(x, y)^2 - \mu^2 \end{aligned} \quad (3.8)$$

$$f_{isher} = \frac{|\mu_1 - \mu_2|}{\sqrt{v_1^2 + v_2^2}}$$

$f(x,y)$  este valoarea componentei culorii, roșu, verde sau albastru,  $n$  este numărul de pixeli din clasă,  $\mu$  este media valorilor din clasă și  $v$  este varianța. Distanța combinată este:

$$dist = \sqrt{RFisher^2 + GFisher^2 + BFisher^2} \quad (3.9)$$

Două regiuni sunt unite dacă distanța combinată este sub un anumit prag. După pasul inițial de clasificare, regiunile sunt clasificate după reguli simple, gen drumul este gri, cerul albastru, iarba verde.

#### *Extragerea suprafeței drumului pe baza spațiului de culoare HSI și a constrângerilor spațiale*

Problema cu spațiul RGB este că este foarte dificil de a proiecta o metrică semnificativă pentru discriminarea culorilor din punctul de vedere al percepției umane. Unul din spațiile de culoare care încearcă rezolvarea acestei probleme este spațiul Hue, Saturation, Intensity (HSI). Lucrarea [Sotelo2004] arată cum spațiul HSI se poate folosi la detecția suprafeței drumului.

Culoarea unui pixel se transformă în spațiul HSI prin următoarele ecuații:

$$\begin{bmatrix} I \\ V_1 \\ V_2 \end{bmatrix} = \begin{bmatrix} \frac{1}{3} & \frac{1}{3} & \frac{1}{3} \\ \frac{-1}{\sqrt{6}} & \frac{-1}{\sqrt{6}} & \frac{2}{\sqrt{6}} \\ \frac{1}{\sqrt{6}} & \frac{-2}{\sqrt{6}} & \frac{1}{\sqrt{6}} \end{bmatrix} \cdot \begin{bmatrix} R \\ G \\ B \end{bmatrix} \quad (3.10)$$

$$H = \tan^{-1} \frac{V_2}{V_1} \quad (3.11)$$

$$S = \sqrt{V_1^2 + V_2^2} \quad (3.12)$$

Spațiul rezultat este cilindric. Intensitatea este axa cilindrului, saturația, care indică puritatea culorii, este distanța față de axă, iar hue, culoarea propriu zisă, este unghiul în jurul axei.

Pentru a putea clasifica pixelii, se stabilește o culoare de referință pentru drum, folosind, de exemplu, predicția. Culoarea de referință va avea valorile  $H_p, S_p, I_p$ . Un pixel cu valorile  $H_i, S_i, I_i$  va avea următoarele distanțe față de culoarea de referință:

Distanța de intensitate:

$$d_{\text{intensity}} = |I_p - I_i| \quad (3.13)$$

Distanța cromatică:

$$d_{\text{chromatic}} = \sqrt{S_p^2 + S_i^2 - 2S_p S_i \cos \theta} \quad (3.14)$$

$$\theta = \begin{cases} |Hp - Hi| & , \text{if } |Hp - Hi| < 180^\circ \\ 360^\circ - |Hp - Hi| & , \text{if } |Hp - Hi| > 180^\circ \end{cases} \quad (3.15)$$

Cele două distanțe se folosesc pentru a decide dacă un pixel aparține drumului sau nu. Pragurile pentru aceste distanțe sunt calculate dinamic, pe baza distanței spațiale a unui pixel față de drumul prezis (dacă pixelul este apropiat, pragul este relaxat).

### 3.2.3. Extragerea trăsăturilor prin stereoviziune

Stereoviziunea nu este foarte folosită în detecția drumului, datorită problemelor tehnice ale realizării unui sistem performant, și a sarcinii computaționale semnificative a procesului de corelare. Totuși, stereoviziunea este importantă atunci când se dorește detectarea obstacolelor și măsurarea poziției acestora. Un sistem care are o funcție de detecție a obstacolelor și o funcției de detecție a drumului poate profita de stereoviziune pentru extragerea de trăsături pentru drum.

Majoritatea tehnicilor găsite în literatură folosesc disparitățile, și nu spațiul 3D. În această secțiune se vor prezenta tehnicile bazate pe disparitate, iar tehnicile originale care folosesc spațiul 3D vor fi descrise în capitolul de contribuții.

#### *Stereoviziune cu disparități*

Folosirea disparităților pentru separarea drumului de obstacole este prezentată în [Weber1996]. Se prezintă o tehnică de estimare a parametrilor planului drumului folosind doar disparitățile și poziția unui pixel în imagine. Sistemul optic este considerat canonic.

Un punct pe planul drumului, în sistemul de coordonate al camerei, va satisface ecuația:

$$AX + BY + CZ = h \quad (3.16)$$

$h$  fiind înălțimea camerei deasupra solului. Folosind ecuațiile de proiecție se obține:

$$A \frac{Zx}{f} + B \frac{yZ}{f} + CZ = h \quad (3.17)$$

sau

$$Z = \frac{h}{\frac{Ax}{f} + \frac{By}{f} + C} \quad (3.19)$$

Folosind ecuația binecunoscută a stereoviziunii canonice,  $Z=bf/d$ , putem rescrie ecuația planului în termeni de poziție a punctului în imagine și disparitate:

$$d(x, y) = \alpha x + \beta y + \gamma = \frac{b}{h}(Ax + By + fC) \quad (3.20)$$

Ecuația de mai sus este folosită pentru a selecta punctele care aparțin planului drumului, dacă știm parametrii acestui plan. Acești parametri sunt estimați dinamic pe baza disparităților măsurate ale punctelor din scenă, și a folosirii unui proces de urmărire. Tehnici similare pot fi găsite în [Franke1999] și [Labayrade2003].

### 3.3. Tehnici de estimare pentru urmărirea benzilor

În acest capitol vom analiza mai multe metode de estimare pentru parametrii benzii de circulație. Singurul mod în care detecția drumului poate fi implementată într-un mod robust este prin folosirea metodelor bazate pe model, deoarece modelul va încorpora unele presupuneri care vor permite algoritmilor să reziste în fața zgomotului și a informațiilor false din setul de măsurători. Unele din metodele analizate în acest capitol nu sunt estimatori probabilistici, dar ei se potrivesc în evoluția naturală a tehnicilor folosite tradițional pentru rezolvarea acestei probleme.

#### 3.3.1. Urmărirea benzilor prin filtrul Kalman

Urmărirea drumului folosind filtrul Kalman a fost pentru prima dată folosită de Dickmanns [Dickmanns1992], și de atunci multe soluții funcționale au fost implementate de cercetători. Filtrul Kalman se bazează pe predicția bazată pe model pentru a stabili regiuni de căutare pentru detecție, și folosește rezultatele detecției pentru actualizarea stărilor. Această metodă presupune o continuitate a parametrilor drumului, iar discontinuitățile sunt tratate prin reinițializarea sistemului.

*Potrivirea unui model 3D al drumului la imagini 2D folosind un filtru Kalman extins cu un singur nivel*

Algoritmii descriși în [Goldbeck1999] sunt o aplicare directă a filtrului Kalman extins la estimarea parametrilor drumului. Vectorul de măsură are ca componente coordonatele laterale ale delimitatorilor drumului, dându-se coordonatele verticale. Funcția de măsură  $\mathbf{g}$  este corespondența dintre modelul 3D al drumului la coordonatele imagine, incluzând transformarea sistemelor de coordonate.

Ciclul de procesare este compus din următorii pași:

- a) Predicția parametrilor drumului folosind ecuațiile de mișcare, și predicția măsurătorii folosind funcția de măsură  $\mathbf{g}$ .



- b) Căutarea delimitatorilor drumului, ca mijlocul unei tranziții întuneric-lumină-întuneric. Aceste coordonate vor forma vectorul de măsură  $Y$ .
- c) Actualizarea stării  $X$  prin folosirea ecuațiilor de corecție ale filtrului.

*Filtru Kalman în doi pași pentru estimarea drumului în imagini monoculare de intensitate*

Vom analiza metoda descrisă în [Aufrere2001], [Chapuis2000], [Chapuis1999], [Chausse2000] și [Aufrere2000], care folosește un filtru Kalman recursiv pentru potrivirea modelului în spațiul imagine. Drumul este descris de următoarele ecuații, în sistemul de coordonate propriu.

$$\begin{aligned} X &= C_l \frac{Y^2}{2} \\ Z &= 0 \end{aligned} \quad (3.21)$$

Camera este plasată la înălțimea  $z_0$  deasupra planului drumului, și are un unghi de aplecare  $\alpha$ , care poate varia în timp. Camera poate fi deplasată față de centrul drumului cu  $x_0$ , și poate face un unghi  $\psi$  cu axa de distanță a sistemului,  $Y$ . Ecuațiile drumului în sistemul camerei devin:

$$\begin{aligned} X &= C_l \frac{Y^2}{2} - \psi Y - x_0 \\ Z &= -z_0 + \alpha Y \end{aligned} \quad (3.22)$$

Mai multe presupuneri sunt folosite: unghiul de înclinare laterală este neglijabil, și drumul are o lățime constantă  $L$ . Folosind aceste formule, și ecuațiile de proiecție, se pot deriva ecuații pentru coordonatele laterale ale marcajelor în imagini, dându-se coordonatele verticale.

$$\begin{cases} u_l = E_u \left( -C_l \frac{E_v z_0}{2(v - \alpha E_v)} - \psi + \frac{v - \alpha E_v}{E_v z_0} \left( x_0 + \frac{L}{2} \right) \right) \\ u_r = E_u \left( -C_l \frac{E_v z_0}{2(v - \alpha E_v)} - \psi + \frac{v - \alpha E_v}{E_v z_0} \left( x_0 - \frac{L}{2} \right) \right) \end{cases} \quad (3.23)$$

Scopul algoritmului este estimarea vectorului de localizare  $\mathbf{X}_l = (x_0, \psi, \alpha, C_l, L)$ , prin estimarea unui vector intermediar de detecție  $\mathbf{X}_d = (u_{1l}, u_{2l}, \dots, u_{nl}, u_{1r}, u_{2r}, \dots, u_{nr})$ .

Se construiește un vector global  $\mathbf{X} = [\mathbf{X}_l \ \mathbf{X}_d]$ , care va conține informația de detecție și informația de localizare. Acest vector va avea o matrice de covarianță  $\mathbf{C}_X$  care conține matricele de covarianță ale celor doi vectori plus informația de corelare dintre aceștia. Aceste matrice se calculează prin antrenare pe mai multe exemple.

a) Algoritmul de detecție

Vectorul de detecție mediu  $\mathbf{X}_d(0)$  este folosit ca o estimare inițială pentru marginile benzii. Se definesc zone de căutare în jurul punctelor date de  $\mathbf{X}_d(0)$ , având lățimea specificată de diagonala matricei de covarianță.




Fig. 3.4. Intervalele de căutare.

În intervalul de căutare, se caută maximele gradientilor pentru fiecare rând din imagine, și o metodă de potrivire a unei linii prin metoda celor mai mici pătrate este aplicată. Se extrag parametrii  $a$  și  $b$  încât  $u = av + b$ . Această linie este folosită pentru a extrage pozițiile  $u_i$  și  $u_{i+1}$ , prin intersectarea ei cu marginea superioară și inferioară a zonei. Se folosește o metodă simplă de validare: dacă linia este inclusă în zona de căutare, linia este considerată validă. Pentru actualizarea vectorului de detecție se folosesc ecuațiile primului nivel din filtrul Kalman.

Un vector de măsură este format ca  $\mathbf{Y} = [u_i, u_{i+1}]^T$ . Starea de estimat este  $\mathbf{X}_d$ , iar matricea ei de covarianță este  $\mathbf{C}_d$ . Nu există zgomot de tranziție, și matricea de tranziție a stărilor este matricea identitate. Matricea care trebuie redefinită pentru fiecare regiune procesată este matricea de măsură  $\mathbf{H}$  care are următoarea formă:

$$\mathbf{H} = \begin{bmatrix} 0 & \dots & 0 & 1 & 0 & 0 & \dots & 0 \\ 0 & \dots & 0 & 0 & 1 & 0 & \dots & 0 \end{bmatrix} \quad (3.24)$$

Toate elementele sunt zero, cu excepția  $\mathbf{H}(1,i)$  și  $\mathbf{H}(2,i+1)$ .

Altă matrice implicată în procesul de actualizare a vectorului de detecție este cea a covarianței zgomotului de măsură, care are o valoare fixă,  $\mathbf{R} = 5^2 \mathbf{I}_2$ . Ecuațiile de actualizare sunt:

$$\begin{cases} \mathbf{K}_d = \mathbf{C}_d \mathbf{H}^T [\mathbf{H} \mathbf{C}_d \mathbf{H}^T + \mathbf{R}]^{-1} \\ \mathbf{X}_{d\text{new}} = \mathbf{X}_d + \mathbf{K}_d [\mathbf{Y} - \mathbf{H} \mathbf{X}_d] \\ \mathbf{C}_{d\text{new}} = \mathbf{C}_d - \mathbf{K}_d \mathbf{H} \mathbf{C}_d \end{cases} \quad (3.25)$$

Vectorul  $\mathbf{X}_d$  și matricea  $\mathbf{C}_d$  sunt actualizate prin filtrul Kalman, și sunt apoi folosite pentru a defini noi zone de căutare. Procesul este repetat iterativ până când s-a reușit potrivirea a suficiente regiuni de căutare la datele din imagine. Dacă algoritmul ajunge la un punct unde nu se mai pot potrivi regiuni, se va întoarce (backtrack) la un nivel anterior de adâncime, și va procesa altă regiune.

#### b) Estimarea parametrilor drumului

Duă ce vectorul  $\mathbf{X}_d$  este estimat, trebuie estimat  $\mathbf{X}_l$ , care conține parametrii drumului. Metoda se bazează pe faptul că există un vector global  $\mathbf{X}$  care conține pe  $\mathbf{X}_d$  și  $\mathbf{X}_l$ , și care leagă cei doi vectori prin matricea globală de covarianță  $\mathbf{C}_x$ .

Matricea de măsură  $\mathbf{H}_X$  se definește în așa fel încât  $\mathbf{X}_d = \mathbf{H}_X * \mathbf{X}$ . Predicția este considerată a fi valoarea inițială din faza de antrenare,  $(\mathbf{X}(0))$ , cu matricea de covarianță  $\mathbf{C}_X(0)$ . Dacă se combină urmărirea cu detecția, valorile precise pentru  $\mathbf{X}$  și  $\mathbf{C}_X$  sunt mai actuale.

$$\begin{cases} \mathbf{K}_x = \mathbf{C}_x(0)\mathbf{H}_x^T[\mathbf{H}_x\mathbf{C}_x(0)\mathbf{H}_x^T + \mathbf{C}_d]^{-1} \\ \mathbf{X} = \mathbf{X}(0) + \mathbf{K}_x[\mathbf{X}_d - \mathbf{H}_x\mathbf{X}(0)] \\ \mathbf{C}_x = \mathbf{C}_x(0) - \mathbf{K}_x\mathbf{H}_x\mathbf{C}_x \end{cases} \quad (3.26)$$

### 3.3.2. Estimarea drumului utilizând filtrul bazat pe particule

În [Southall2001] se prezintă o metodă de estimare pe baza tehnicii „condensation”, folosind punctele de marcaj ca trăsături de măsură. Fiecare punct din imagine primește un scor bazat pe distanța față de cel mai apropiat marcaj, iar scorurile sunt folosite pentru a calcula ponderea pentru fiecare particulă. Sistemul folosește re-eșantionarea partiționată, și particule de inițializare pentru a aborda discontinuitățile. În [Macek2004] găsim un sistem care folosește metoda particulelor pentru a fuziona multiple indicii (culoare, muchii, Laplacian of Gaussian). Pentru fiecare indice se face compararea dintre date și ipoteze, se calculează verosimilități, și se combină prin multiplicare.

Simplitatea prin care o soluție bazată pe particule abordează măsurătorile permite integrarea unei largi palete de indicii. Acesta este cazul metodei de detecție a drumurilor de țară prezentate în [Franke2007], unde spațiul imagine este divizat în regiuni drum și non-drum, și fiecare pixel din aceste regiuni contribuie la rezultatul final prin intensitate, culoare, textură și gradient. Tehnicile prezentate în [Smuda2006] arată valoarea filtrului bazat pe particule pentru fuzionarea informațiilor eterogene, când informațiile din imagine sunt combinate cu informații oferite de GPS și de hartă.

*Fuzionarea indicilor multiple într-un cadru bazat pe tehnica „Condensation”.*

Vom analiza mai în detaliu tehnica descrisă în [Macek2004]. Această tehnică folosește mai multe rezultate ale unor algoritmi de procesare a imaginilor ca indicii pentru ponderarea particulelor.

a) Potrivirea modelului folosind detectorul de muchii Canny și transformata Hough:

Un model simplu 3D al drumului (drum drept, fără curbura) se proiectează în imagine ca două drepte. Pentru a se găsi aceste drepte, se aplică transformata Hough la muchiile obținute prin Canny. Cele două drepte devin două puncte în spațiul Hough.

$c_l^{(i)} = \{\theta_{cl}^{(i)}, \rho_{cl}^{(i)}\}$  - Marginea stângă

$c_r^{(i)} = \{\theta_{cr}^{(i)}, \rho_{cr}^{(i)}\}$  - Marginea dreaptă.

Se definește o rază prag în jurul acestor două puncte, care ține cont de posibilitatea că un delimitator al drumului are mai multe muchii.

$$r_{thresh} = \sqrt{\theta_{thresh}^2 + \rho_{thresh}^2} \quad (3.27)$$

Pentru fiecare interval de căutare se calculează următoarea sumă, care ține cont de toate punctele din spațiul Hough incluse în cercul prag.

$$\delta_{cl}^{(i)} = \sum_{k=1}^N \frac{(r_{thresh} - \sqrt{(\theta_{cl}^{(i)} - \theta^{(k)})^2 + (\rho_{cl}^{(i)} - \rho^{(k)})^2})}{r_{thresh}} I_{cl}^{(k)} \quad (3.28)$$

Ponderea asociată cu acest indiciu este dată de următoarea ecuație, care combină ponderile pentru marginea stângă și pentru marginea dreaptă.

$$\omega_{Canny}^{(i)} = \left( \frac{\delta_{cl}^{(i)} - \delta_{cl\min}}{\delta_{cl\max} - \delta_{cl\min}} + p_0 \right) \left( \frac{\delta_{cr}^{(i)} - \delta_{cr\min}}{\delta_{cr\max} - \delta_{cr\min}} + p_0 \right) \quad (3.29)$$

$p_0$  este un factor constant, pentru ca nici o probabilitate să nu fie zero.

b) Testarea ipotezelor folosind Laplacian of Gaussian (LoG):

Imaginea de muchii obținută prin aplicarea LoG are muchii mai late, și astfel validarea ipotezelor poate fi făcută prin numărarea punctelor care corespund marginilor prezise.

Pentru fiecare margine, se calculează:

$$\delta_{l,r}^{(i)} = \sum_{k=1}^{N_{l,r}} I_{l,r}^{(k)} \quad (3.30)$$

Unde  $N$  este numărul de pixeli din marginea prezisă, și  $I(k)$  este 1 când pixelul este pe o muchie, altfel 0.

Verosimilitatea acestei măsuri este:

$$\omega_{LoG}^{(i)} = \left( \frac{\delta_l^{(i)} - \delta_{l\min}}{\delta_{l\max} - \delta_{l\min}} + p_0 \right) \left( \frac{\delta_r^{(i)} - \delta_{r\min}}{\delta_{r\max} - \delta_{r\min}} + p_0 \right) \quad (3.31)$$

c) Testarea ipotezelor folosind culoarea

Testarea prin culoare se efectuează pe trei regiuni, (marcajul stâng, zona centrală dintre marcaje, marcajul drept), și rezultatul este produsul a trei factori:

$$\omega_{Color}^{(i)} = \left( \frac{\delta_l^{(i)} - \delta_{l\min}}{\delta_{l\max} - \delta_{l\min}} + p_0 \right) \left( \frac{\delta_r^{(i)} - \delta_{r\min}}{\delta_{r\max} - \delta_{r\min}} + p_0 \right) \left( \frac{\delta_c^{(i)} - \delta_{c\min}}{\delta_{c\max} - \delta_{c\min}} + p_0 \right) \quad (3.32)$$

Cantitățile  $\delta$  sunt numărul de pixeli care au culoarea așteptată în fiecare regiune.

Ponderea finală a particulelor este produsul ponderilor individuale ale fiecărui algoritm.

## 4. Senzorul bazat pe stereoviziune


Un algoritm de urmărire performant are următoarele componente: un bun model pentru procesul de urmărit, o bună tehnică de estimare bazată pe probabilități, și o bună metodă de extragere a trăsăturilor. Natura activității noastre de cercetare implică trăsături derivate din procesarea imaginilor. O imagine, sau o secvență de imagini, poate produce trăsături precum muchii, valori ale gradientului, zone texturate, vectori de flux optic, etc. Totuși, o aplicație pentru asistența conducerii auto necesită, la un moment dat, ca rezultatele să fie raportate la lumea reală, într-un sistem de coordonate 3D. Informația 3D poate fi inferată dintr-o singură imagine, pe baza unor presupuneri sau cunoștințe, sau poate fi extrasă din procesarea perechilor de imagini, prin stereoviziune.

O soluție bazată pe stereoviziune folosește două surse de imagini, privind aceeași scenă din două puncte diferite. Metode precise de calibrare permit găsirea parametrilor cu care algoritmi software efectuează triangulația pentru extragerea informațiilor 3D.

În ultimii ani, colectivul de cercetare în domeniul procesării imaginilor, din cadrul Universității Tehnice din Cluj-Napoca, a dezvoltat și utilizat mai multe metode de stereoviziune, adaptate la diferite probleme specifice.

### 4.1. Calibrarea camerelor

Pentru a se putea reconstrui mediul 3D prin stereoviziune, camerele trebuie calibrate, aceasta însemnând estimarea parametrilor intrinseci și extrinseci. Parametrii intrinseci sunt calibrați pentru fiecare cameră individual, estimându-se distanța focală, coordonatele punctului principal și coeficienții de distorsiune. Parametrii sunt estimați folosind metoda Bouguet [Bouguet2008].



a.

b.

Fig. 4.1. a. Configurații ale modelului de calibrare folosit pentru calibrarea intrinsecă. b. Scena de calibrare pentru estimarea parametrilor extrinseci.

Metodele generale de calibrare, precum [Bouguet2008], oferă soluții pentru calibrarea extrinsecă, dar folosesc același obiect de calibrare ca și pentru calibrarea parametrilor intrinseci. Aceste metode pot fi folosite pentru reconstrucție la apropiere, dar nu sunt potrivite pentru reconstrucția la distanță, pentru scene de trafic auto. Astfel, s-a dezvoltat o metodă nouă pentru determinarea parametrilor extrinseci, care se bazează pe o scenă de calibrare de dimensiuni mari, construită din ținte în formă de X. Poziția 3D a fiecărei ținte este măsurată, și poziția acestor ținte în imagine este determinată automat, cu precizie de sub-pixel. Parametrii extrinseci se calculează prin minimizarea erorilor de proiecție a țintelor în planul imagine, prin metoda Gauss-Newton.

## 4.2. Reconstrucția stereo folosind geometria epipolară

Algoritmul de reconstrucție stereo folosit este în mare parte cel găsit în literatura de specialitate [Trucco1998]: găsirea perechilor de trăsături în imaginea stângă și dreaptă, și efectuarea triangulației.

Pentru prima noastră soluție stereo, aveam de ales între geometria epipolară (generală) și geometria bazată pe rectificare. Rectificarea implică reproiecția imaginilor stângă și dreaptă în așa fel încât noua pereche de imagini să pară provenită de la camere identice, perfect aliniată, lipsite de distorsiuni.

Metodele bazate pe rectificare au avantajul unei căutări rapide, urmată de o și mai simplă reconstrucție 3D. Cu optimizare hardware, sau cu rezoluție a imaginilor suficient de joasă, se pot obține hărți de disparitate dense. Cel mai important neajuns al acestei metode este pierderea de calitate prin procesul de rectificare. Din acest motiv, rectificarea nu a fost folosită în primul nostru sistem, ci doar mai apoi, când a apărut nevoia de date stereo dense.

Pentru a asigura un răspuns în timp real, s-au folosit doar punctele aparținând muchiilor în procesul de corelare. Pentru corespondență, s-a folosit corelarea pe regiuni, folosind ca metrică suma diferențelor absolute [Williamson1998], calculată cu funcții SSE ale procesorului Intel. Pentru a asigura o rată scăzută a erorilor, doar corespondențele care sunt ne-ambigue (cea mai bună corespondență are o valoare semnificativ mai mică a funcției diferență față de a doua candidată) sunt menținute [Nedevschi2004]. Pentru a mări precizia, căutarea corespondenței la nivel de sub-pixel este realizată prin potrivirea unei parabole în vecinătatea punctului găsit, și găsirea vârfului acesteia.




Fig. 4.2. Reconstrucția la nivel de sub-pixel. a) Imaginea perspectivă b) Vedere de sus a punctelor 3D, reconstruite fără interpolare sub-pixel c) Vedere de sus a punctelor 3D, cu rezoluție de sub-pixel.

## 4.3. Reconstrucția stereo densă pentru aplicații urbane

Soluția anterioară, bazată pe muchii, are avantajul că mai puține puncte sunt considerate pentru corelare. Traficul urban, însă, impune folosirea unui număr mai mare de date, pentru o reconstruire mai bună a obstacolelor și a drumului. Pentru menținerea performanțelor de timp real, sarcina de a găsi corelațiile între trăsăturile din imaginea stângă și cele din imaginea dreaptă este lăsată în seama unui coprocesor hardware specializat.

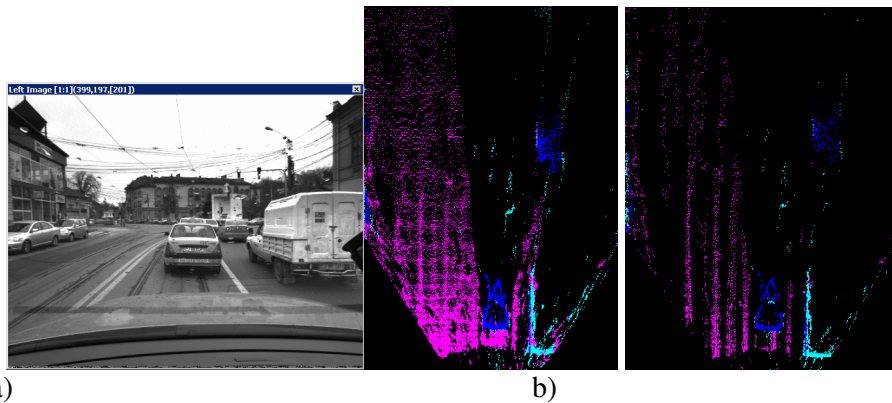


Fig. 4.3. Stereoviziune densă b) față de cea bazată pe muchii c), pentru aceeași scenă a)

## 5. Soluții originale pentru urmărirea drumului bazate pe stereoviziune

### 5.1. Sistem de urmărire a drumului pentru autostrăzi și drumuri rurale, bazat pe filtrul Kalman

În acest capitol se prezintă un sistem care folosește, în premieră, informația stereo sub forma unui set de puncte 3D, reducând nevoia de presupuneri pe care alte sisteme similare le foloseau.

#### 5.1.1. Modelarea benzii de circulație

Modelul drumului cu benzi multiple are două părți: modelul benzii curente, și modelul benzilor laterale. Banda curentă este modelată ca o suprafață clotoidală. Modelul clotoidal are avantajul de a acoperi o mare plajă de scenarii posibile, și fiecare parametru are o semnificație fizică. De asemenea, acest model permite modelarea dinamică eficientă. Parametrii modelului sunt:

- $W$  – lățimea benzii
- $c_{h,0}$  – curbura orizontală
- $c_{h,1}$  – variația curburii orizontale
- $c_{v,0}$  – curbura verticală
- $c_{v,1}$  – variația curburii verticale
- $X_{cw}$  – deplasamentul lateral
- $\alpha, \gamma, \psi$  – unghiurile de aplecare, înclinare și orientare

Starea benzii curente este modelată ca o distribuție de probabilitate Gaussiană, cu vectorul de parametri  $\mathbf{X}_{\text{current}}$  ca medie, și cu o matrice de covarianță  $\mathbf{P}_{\text{current}}$ .

Benzile adiacente sunt modelate doar prin lățimea lor.

#### 5.1.2. Predicția

*Prezicerea parametrilor 3D ai drumului*

Ecuția care calculează vectorul de stare prezis  $\bar{\mathbf{X}}_i$  folosind estimarea din trecut  $\mathbf{X}_{i-1}$  este:

$$\mathbf{X}_i = \mathbf{F}_i \mathbf{X}_{i-1} + \mathbf{B}_i \mathbf{u}_i \quad (5.1)$$

Matricele  $\mathbf{F}_{\text{current},i}$  și  $\mathbf{B}_{\text{current},i}$  sunt descrise de ecuațiile 3.5 și 3.6, din capitolul 3. Aceste ecuații se bazează pe parametrii de mișcare ai vehiculului:  $v_i$  – viteza,  $\Delta t_i$  – timpul scurs de la ultima măsurătoare, și  $e_i$  – curbura traiectoriei.

*Matricea de covarianță a predicției*

Matricea de covarianță  $\bar{\mathbf{P}}_i$  exprimă incertitudinea predicției.

$$\bar{\mathbf{P}}_i = \mathbf{F}_i \mathbf{P}_{i-1} \mathbf{F}_i^T + \mathbf{B}_i \mathbf{T}_i \mathbf{B}_i^T + \mathbf{Q}_i \quad (5.2)$$

Termenii implicați sunt:

$\mathbf{P}_{i-1}$ : matricea de covarianță a stării anterioare  $\mathbf{X}_{i-1}$ .

$\mathbf{T}_i$ : matricea de covarianță a intrării, de 1x1 elemente, asociată cu  $e_i$ .

$\mathbf{Q}_i$ : are dimensiunea de 11x11 elemente, exprimă incertitudinea la tranziția stărilor. Valorile din  $\mathbf{Q}_i$  sunt proporționale cu timpul trecut între măsurători.

*Predicția aspectului 2D în spațiul imagine*

Algoritmul de detecție a benzii folosește informații din spațiul 3D și din spațiul 2D, pentru a putea beneficia de avantajele ambelor spații. Pentru lucrul în spațiul imagine se definește o funcție de transformare, care va converti vectorul de stare  $\mathbf{X}$  într-un vector de descriere în spațiul imagine,  $\mathbf{X}_D$ . Se va calcula și Jacobianul acestei transformări  $\mathbf{H}_D$ , care va fi utilizat apoi pentru filtrul Kalman.

$$(\mathbf{X}_D, \mathbf{H}_D) = \text{ImageSpaceMapping}(\mathbf{X}, \mathbf{P}) \quad (5.3)$$

Procesul *ImageSpaceMapping* este definit printr-o funcție  $\mathbf{h}$ ,

$$\mathbf{X}_D = \mathbf{h}(\mathbf{X}) \quad (5.4)$$

Funcția  $\mathbf{h}$  nu este o funcție propriu zisă, ci un algoritm de proiecție care va fi descris în cele ce urmează.



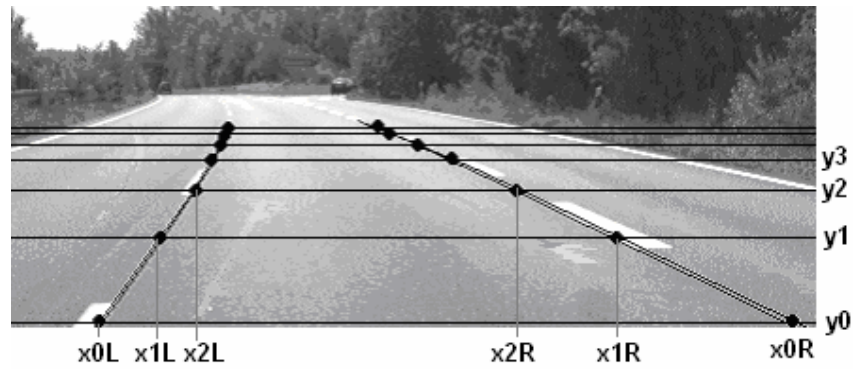


Fig. 5.1. Liniile de control orizontale, și marcajele benzilor.

Vectorul din spațiul imagine,  $\mathbf{X}_D$  are forma  $\mathbf{X}_D = (x_{1l}, x_{2l}, \dots, x_{nl}, x_{1r}, x_{2r}, \dots, x_{nr})$ . Valorile  $x_{li}$  și  $x_{ri}$  sunt coordonatele  $x$  ale delimitatorilor stâng și drept ai benzii, pentru un șir de valori  $y$  date. Valorile  $y_i$  formează linii orizontale, ca în figura 5.1, și prin găsirea coordonatelor  $x$  vom defini complet aspectul benzii în imagine.

Coordonatele  $y_i$  sunt obținute prin proiecția unei serii de puncte cu zero  $X$  și coordonate  $Z$  cunoscute în planul imaginii. Coordonatele  $Y$  se calculează prin aplicarea ecuațiilor profilului vertical. Se obțin punctele îngroșate din figura 5.2. Aceste puncte formează curba  $A$ , care este proiecția profilului vertical, neglijând coordonata  $X$ , în planul imaginii.




Fig. 5.2. Liniile de  $Z$  constant nu sunt orizontale

Pentru fiecare  $Z_i$  se calculează coordonata  $X_i$  a marginii stângă și dreaptă a benzii, aplicând ecuațiile profilului orizontal.

Se vor obține două puncte 3D pentru fiecare  $Z_i$ :  $(X_{L,i}, Y_{L,i}, Z_i)$  și  $(X_{R,i}, Y_{R,i}, Z_i)$ , pentru partea stângă și pentru partea dreaptă. Linia formată de cele două puncte nu este orizontală, cum se vede din figura 5.2. Pentru a se obține coordonatele  $x$  din imagine pentru valori fixe ale lui  $y$ , se calculează intersecțiile dintre marginile  $C$  din figura 5.2, cu drepte orizontale definite de sirul de valori  $y_i$ .

Acest algoritm de transformare poate efectua proiecția oricărei geometrii a drumului, schimbând ecuațiile profilului vertical sau orizontal. Nu mai există necesitatea de a avea curbura verticală nulă, sau absența unghiului de înclinare, sau camere rectificată. Acest algoritm este o îmbunătățire considerabilă față de ecuațiile de transformare descrise în [Aufreere2001] sau [Kluge1995].

Pasul următor este calcularea matricei Jacobian pentru această transformare. Rândul  $i$  și coloana  $j$  din această matrice sunt date de:

$$H_D[i, j] = \frac{\partial h[i]}{\partial X[j]}(\mathbf{X}) \quad (5.5)$$

Din cauza faptului că funcția  $h$  nu este analitică, diferențierea trebuie făcută numeric, prin alterarea fiecărui element al vectorului de stare și calcularea răspunsului funcției, efectuându-se apoi raportul diferențelor.

### 5.1.3. Procesul de măsură – detecția benzii de circulație

#### 5.1.3.1. Detecția profilului vertical

O componentă vitală și definitorie a soluției noastre, profilul vertical va fi abordat ținându-se cont de următoarele fapte:

- Mulțimea punctelor 3D este zgomotoasă.
- Prezența obstacolelor introduce probleme adiționale.




Fig. 5.3. Vedere laterală a punctelor 3D.

Pentru detecția profilului vertical, vom considera următoarele presupuneri simplificatoare:

- În zona de șosea apropiată de noi, punctele pot fi considerate a fi pe o linie dreaptă.
- Efectul unghiului de înclinare este neglijabil pentru proiecția laterală a punctelor.

#### *Detecția unghiului de aplecare*

Algoritmul de detecție al unghiului de aplecare:

1. Construirea unei histograme polare, având 500 de valori, fiecare valoare corespunzând unui unghi multiplu de 0.008 grade, simetrică față de poziția centrală, corespunzătoare unghiului de aplecare zero. Această histogramă permite reprezentarea unghiurilor între  $-2 \dots 2$  grade. Construcția histogramei se face astfel:

- a. Pentru fiecare punct 3D din intervalul de distanță 0-40m

- Se calculează indexul din histogramă:

$$i = \frac{\tan^{-1} \frac{Y}{Z}}{0.008} + 250 \quad (5.6)$$

- Se adaugă la valoarea  $i$  din histogramă cantitatea  $\left(\frac{Z}{K}\right)^2$ ,  $K$  fiind un factor de normalizare cu valoarea 120000.

- b. Se netezește histograma prin convoluție cu nucleul  $[1 \ 3 \ 1]$  de trei ori.

2. Se găsește valoarea maximă din histogramă.
3. Începând din poziția cea mai de jos din histogramă, (0, corespunde unei valori a unghiului de  $-2$  grade), se compară fiecare valoare cu  $2/3$  din valoarea maximă. Prima valoare găsită se reține.
4. Se convertește această poziție în valoare angulară.  
 $angle = (position - 250) * 0.008$  grade.

Unghiul găsit este unghiul de aplecare.

#### *Detecția curburii verticale*

Având unghiul de aplecare, următorul pas este calcularea curburii verticale. Se aplică următorul algoritim:

1. Se construiește o histogramă de curburi, cu 500 de poziții, diferența dintre poziții fiind o diferență a curburii de  $2.3e-6/500$  radiani pe milimetru. Histograma se construiește astfel:
  - a. Pentru fiecare punct 3D din zona de distanță 20-70m
    - Se calculează poziția în histogramă:
 
$$i = \frac{2 \cdot \frac{Y - \alpha Z}{Z^2}}{2.3 \cdot 10^{-6}} \cdot 500 \quad (5.7)$$
    - Se adaugă la valoarea histogramei din poziția găsită cantitatea  $\left(\frac{Z}{K}\right)^2$ ,  $K$  fiind factor de normalizare egal cu 120000.
  - b. Se netezește histograma prin convoluție cu nucleul [1 2 1]
2. Se găsește maximul histogramei.
3. Se găsește prima valoare din histogramă care este mai mare sau egală cu  $\frac{1}{2}$  din maxim, pornind de jos în sus.
4. Se convertește această poziție într-o valoare a curburii.

#### **5.1.3.2. Detecția profilului orizontal**

##### *Selecția punctelor de drum*

Pe baza profilului vertical se pot selecta punctele care aparțin suprafeței drumului. O eroare de  $\pm 20$  cm pe axa Y este permisă pentru compensarea unghiului de înclinare și pentru alte erori. Punctele 3D corespunzătoare drumului sunt reprojctate în spațiul imagine, unde se vor executa următorii pași ai detecției.

##### *Generarea zonelor de căutare*

Vectorul predicție  $\bar{\mathbf{X}}_i$  este folosit pentru a genera zone de căutare pentru potrivirea modelului, potrivire executată în spațiul imagine. Pentru generarea zonelor de căutare, se folosește profilul vertical deja detectat, și se combină cu vectorul de stare prezisă, obținând un nou vector  $\bar{\mathbf{X}}_i^V$ . Acest vector este proiectat în spațiul imagine cu funcția de transformare definită.

$$(\mathbf{X}_D, \mathbf{H}_D) = \text{ImageSpaceMapping}(\bar{\mathbf{X}}_i^V, \bar{\mathbf{P}}_i) \quad (5.8)$$

Matricea de covarianță a proiecției în imagine este calculată ca:

$$\mathbf{P}_D = \mathbf{H}_D \bar{\mathbf{P}}_i \mathbf{H}_D^T + \mathbf{R} \quad (5.9)$$

Zonele de căutare sunt trapezoidale, definite de media  $\mathbf{X}_D$ , și de diagonala matricei de covarianță  $\mathbf{P}_D$ .

#### *Procesarea unei regiuni de căutare*

Pentru fiecare regiune se face potrivirea de segmente la mulțimea punctelor conținute. Punctele de muchie corespunzătoare punctelor 3D de pe drum se pot folosi ca atare, sau se poate utiliza o metodă de clasificare a marcajelor, ca cea descrisă în capitolul 5.2. În fiecare caz, punctele vor primi o clasă specifică. Clasificarea punctelor aduce o ponderare diferită a acestora, în funcție de importanța clasei.

Punctele sunt partiționate în submulțimi, fiecare submulțime conținând puncte dintr-o singură clasă. Pentru fiecare submulțime se aplică metoda celor mai mici pătrate pentru potrivirea dreptelor. Panta și deplasamentul dreptei sunt date de următoarele ecuații:

$$m = \frac{n \sum_{k=0}^n x(k)y(k) - \sum_{k=0}^n x(k) \sum_{k=0}^n y(k)}{n \sum_{k=0}^n y(k)^2 - (\sum_{k=0}^n y(k))^2} \quad (5.10)$$

$$x_0 = \frac{\sum_{k=0}^n y(k)^2 \sum_{k=0}^n x(k) - \sum_{k=0}^n y(k) \sum_{k=0}^n x(k)y(k)}{n \sum_{k=0}^n y(k)^2 - (\sum_{k=0}^n y(k))^2} \quad (5.11)$$

Pentru fiecare mulțime vom avea următoarele rezultate:

- Parametrii dreptei:  $x_{0,k}$ ,  $m_k$
- Numărul de puncte din fiecare submulțime  $N_k$
- Ponderea specifică a clasei:  $W_k$
- Deviația standard a erorii de potrivire a dreptei la punctele din clasă:

$$\sigma_k = \sqrt{\frac{1}{N_k - 1} \sum_{j=1}^{N_k} (m_k y_j + x_{0,k} - x_j)^2} \quad (5.12)$$

Pentru fiecare clasă  $i$  se atașează un scor dat de ecuația:

$$M_k = \begin{cases} 0, & \text{if } N_i < 3 \\ \alpha_N \frac{N_k}{S} + \alpha_W W_k + \frac{\alpha_\sigma}{\sigma_k}, & \text{otherwise} \end{cases} \quad (5.13)$$

Submulțimea care maximizează acest scor va da dreapta care, prin intersecția ei cu limita superioară și inferioară a regiunii de căutare, va da vectorul de măsură intermediară.




Fig. 5.4. Rezultatul procesării unei regiuni:  $x_i$  și  $x_{i+1}$

Nu toate regiunile conțin segmente de dreaptă valide. Pentru a fi declarată validă, trebuie ca:

- O regiune să aibă mai mult de trei puncte.
- Segmentul de dreaptă rezultat prin potrivire trebuie să fie conținut complet în regiunea de căutare.

#### *Potrivirea recursivă a modelului*

Potrivirea modelului este o căutare recursivă, similară cu cea descrisă în [Aufreere2000]. Regiunile sunt procesate în ordinea distanței lor față de vehicul, într-un model zig-zag, abordare care a fost găsită optimă prin experiment. Căutarea se consideră încheiată atunci când am actualizat modelul de nouă ori, cu cel puțin patru zone de căutare valide pentru fiecare parte. De asemenea, se poate abandona procesul de căutare dacă nu se obține un rezultat într-un interval specific de timp. Rezultatul acestui pas este sub forma unui vector actualizat  $\mathbf{X}_p$ , conținând coordonatele laterale  $x$  ale drumului în spațiul imagine.

#### *Calcularea parametrilor profilului orizontal (refacerea informației 3D)*

Presupunând că avem o detecție reușită, deocamdată avem un vector conținând informație 2D. Acum avem nevoie de parametri care definesc profilul orizontal al drumului, care este 3D. Pentru a găsi coordonatele 3D ale punctelor de margine ale benzii, vom folosi ecuația proiecției din spațiul 3D în spațiul 2D.

$$x = \frac{\mathbf{P}_{0,0}X + \mathbf{P}_{0,1}Y + \mathbf{P}_{0,2}Z + \mathbf{P}_{0,3}}{\mathbf{P}_{2,0}X + \mathbf{P}_{2,1}Y + \mathbf{P}_{2,2}Z + \mathbf{P}_{0,3}} \quad (5.14)$$

Unde  $\mathbf{P}$  este matricea de proiecție.

Pentru a extrage coordonata  $X$ , trebuie să cunoaștem coordonata din imagine,  $x$ , și celelalte coordonate 3D,  $Y$  și  $Z$ , și să rezolvăm ecuația 5.47 pentru  $X$ . Problema este că nu cunoaștem aceste coordonate, deoarece liniile de distanță constantă nu sunt orizontale în imagine, și avem de considerat și unghiul de înclinare laterală.

În loc să găsim coordonatele  $Z$  pentru fiecare punct 2D detectat, vom găsi punctele din imagine  $x$  pentru coordonate  $Z$  cunoscute. Vom intersecta segmentele din imagine, generate de punctele detectate, cu liniile de distanță constantă, și astfel vom avea coordonatele  $x, y$  ale acestei intersecții în spațiul imagine, cunoscând și coordonata  $Z$ . Unghiul de înclinare se consideră egal cu cel din cadrul anterior (va fi actualizat ulterior), iar coordonata  $Y$  va fi disponibilă prin ecuațiile profilului vertical, deja detectat. Coordonata  $X$  se poate calcula astfel:

$$X = \frac{\mathbf{P}_{0,1}Y_C + \mathbf{P}_{0,2}Z + \mathbf{P}_{0,3} - x(\mathbf{P}_{2,1}Y_C + \mathbf{P}_{2,2}Z + \mathbf{P}_{2,3})}{\mathbf{P}_{2,0}x + \mathbf{P}_{2,1}\gamma - \mathbf{P}_{0,0} - \mathbf{P}_{0,1}\gamma} \quad (5.15)$$

Având perechile de coordonate (X,Z) pentru 10 puncte de pe marginea stângă, și 10 puncte de pe marginea dreaptă, avem de fapt 10 ecuații de forma:

$$X_i = -\frac{W}{2} - X_{cw} - \psi Z_i + c_{0,h} \frac{Z_i^2}{2} + c_{1,h} \frac{Z_i^3}{6} \quad (5.16)$$

și 10 de forma:

$$X_i = \frac{W}{2} - X_{cw} - \psi Z_i + c_{0,h} \frac{Z_i^2}{2} + c_{1,h} \frac{Z_i^3}{6} \quad (5.17)$$

Necunoscutele sunt 5 parametri ai benzii, deci sistemul de ecuații este supradeterminat, și se rezolvă prin metoda celor mai mici pătrate.

### 5.1.3.2. Detecția unghiului de înclinare

Singurul lucru rămas neestimat este unghiul de înclinare (roll). Pentru detecția acestuia, vom utiliza regiunile de căutare rezultate în urma procesului de detecție a profilului orizontal, care sunt mult mai restrânse decât cele inițiale.

Punctele 3D luate în considerare trebuie să îndeplinească condițiile:

- Situate în intervalul de distanță 0-40m.
- Proiecția lor în imagine trebuie să aparțină regiunilor descrise anterior.
- Trebuie să fie puncte de tip drum, selectate de profilul vertical.

Pentru fiecare punct se calculează un unghi de înclinare, prin efectuarea diferenței dintre coordonata Y a lui și cea prezisă de profilul vertical, și împărțirea acestei diferențe la coordonata X. Unghiul de înclinare final este medierea acestor unghiuri individuale.

$$\gamma_k = \frac{Y_k - Y_{Ck}}{X_k} \quad (5.18)$$

### 5.1.4. Detecția benzilor adiacente

Benzile adiacente sunt complet descrise de lățimea lor, având restul parametrilor comuni cu banda curentă. Dacă banda curentă nu este detectată, nu se încearcă detecția benzilor adiacente.

#### *Pregătirea punctelor*

Algoritmul utilizează punctele 3D aparținând drumului, deja selectate de profilul vertical. Dacă presupunem că benzile adiacente au aceeași orientare cu banda curentă, putem modifica coordonatele acestor puncte pentru a le alinia cu sistemul de coordonate.

$$X_T = X - X_c(Z) = X - (-X_{cw} - \psi Z + c_{0,h} \frac{Z^2}{2} + c_{1,h} \frac{Z^3}{6}) \quad (5.19)$$

După acest pas, procesarea a devenit mult mai simplă. Pasul următor este să ajustăm distribuția în spațiu a acestor puncte, pentru a compensa variația de densitate a acestora. Vom construi un spațiu discret, reprezentat de o matrice de celule (o grilă). Pentru fiecare punct 3D vom calcula celula lui, și vom marca celula ocupată. Astfel, nu contează câte puncte aparțin unei celule, doar calitatea de ocupată sau liberă. Luăm apoi celulele ocupate și le transformăm din nou în puncte, obținând un set de puncte mult mai uniform.

#### Localizarea benzilor adiacente

Va fi construită o histogramă care va contabiliza numărul de puncte filtrate de-a lungul axei Z, pentru valori discrete X. Ideal, punctele delimitatoare ale unei benzi adiacente se vor alinia și vor produce un vârf semnificativ în histogramă.




Fig. 5.5. Histograma de numărare a punctelor pentru valori discrete ale coordonatelor X

Pentru evidențierea vârfurilor, se analizează valoarea maximă a histogramei, și se măsoară înălțimea de coborâre maximă din acest vârf, raportată la lungimea drumului de coborâre. Un vârf ascuțit va avea raportul dintre înălțimea coborâtă și lungimea traseului de coborâre cât mai mare.




Fig. 5.6. Calcularea coborârii maxime, și a traseului de coborâre.




Fig. 5.7. Poziția delimitatorului benzii laterale.

### 5.1.5. Actualizarea stării benzilor

Actualizarea este pasul final din algoritmul de urmărire. Actualizarea benzii curente, și a benzilor adiacente, se face independent una de alta. Succesul profilului orizontal indică succesul detecției pentru banda curentă, deoarece un profil orizontal detectat implică o selecție bună a punctelor de drum, prin profilul vertical. Actualizarea benzii curente se face prin ecuațiile clasice ale filtrului Kalman liniar.

Dacă detecția benzii curente eșuează, avem două opțiuni: reinițializarea algoritmului, sau menținerea predicției ca estimare, sperând că în cadrele viitoare vom avea detecție. Decizia în privința continuării prin predicție sau re-inițializării o luăm pe baza numărului de succese și eșecuri din trecut. O bandă urmărită cu succes mult timp va tolera câteva eșecuri, una nouă nu. Prea multe eșecuri cumulate vor provoca re-inițializarea indiferent de vechime.

### 5.1.6. Teste și rezultate

#### 5.1.6.1. Scopul testelor, și scenariile de test

Am ales scenariile care vor oferi o testare extensivă a tuturor componentelor sistemului de detecție a drumului: detecția benzii curente, detecția benzilor adiacente, drumuri marcate și nemarcate.

#### 5.1.6.2. Rezultate calitative pe autostradă.

Banda curentă este detectată în aproape orice situație pe autostradă. Dacă ambele margini sunt de tip marcaj întrerupt, pot apărea instabilități ocazionale. Benzile adiacente sunt detectate dacă nu sunt mascate de obstacole, și dacă delimitatorii lor sunt vizibili.

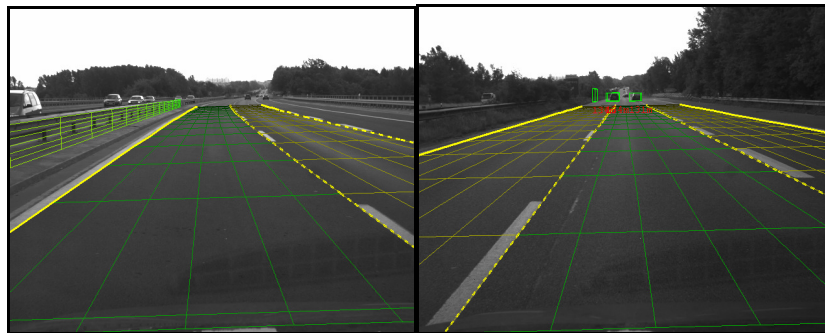


Fig. 5. 8. Rezultate pe autostradă

#### 5.1.6.3. Rezultate calitative în scenariu cu drum nemarcat

Detecția funcționează acceptabil în situațiile de drum nemarcat, dar se observă o scădere a gradului de robustețe față de scenariul autostradă. Cel mai comun scenariu este cel de drum rural, cu mijlocul marcat dar cu extremitățile nemarcate. În aceste situații banda curentă este detectată fără probleme, iar banda adiacentă este detectată dacă nu este mascată.



#### 5.1.6.4. Rezultate cantitative în scenarii controlate

O analiză cantitativă a rezultatelor, în scenarii nemarcate, este dificil de făcut pe imagini reale, deoarece scenariile controlate sunt greu de găsit. Mai mult, unii parametri, precum unghiul de aplecare, de orientare sau de înclinare nu pot fi determinate dinainte, deoarece ei depind de mai mulți factori. Din acest motiv, pentru o evaluare numerică extinsă a algoritmului nostru, am folosit imagini sintetice, unde am simulat inclusiv variația unghiurilor vehiculului față de drum.

Deviația standard a erorilor pentru fiecare parametru estimat este prezentată în tabelul 5.1.

Table 5.1

| Lane parameter       | Error standard deviation |
|----------------------|--------------------------|
| Lane width           | 0.13 m                   |
| H curvature radius   | 71 m                     |
| V curvature radius   | 182 m                    |
| Pitch                | 0.1 deg                  |
| Yaw                  | 0.25 deg                 |
| Roll                 | 0.09 deg                 |
| Position from center | 0.21 m                   |

O evaluare parțială a putut fi efectuată pe imagini reale, luate într-un poligon de testare. Lățimea și curbura benzilor a fost cunoscută, restul parametrilor nefiind accesibili. Rezultatele sunt prezentate în tabelele 5.2 și 5.3

Table 5.2

| Real images<br>200 m curvature lane | Real world parameters | Estimated parameters | Errors |
|-------------------------------------|-----------------------|----------------------|--------|
| Lane width                          | 3.5 m                 | 3.462 m              | 3.8 cm |
| Lane curvature radius               | 200 m                 | 195.5 m              | 4.5 m  |

Table 5.3

| Real images<br>300 m curvature lane | Real world parameters | Estimated parameters | Errors |
|-------------------------------------|-----------------------|----------------------|--------|
| Lane width                          | 3.5 m                 | 3.486 m              | 1.4 cm |
| Lane curvature radius               | 300 m                 | 296.7 m              | 3.3 m  |

#### 5.1.7. Concluzii

Acest capitol descrie o metodă originală de urmărire a benzilor multiple, bazată pe un sistem de stereoviziune ce oferă informație 3D completă. Algoritmul este un estimator probabilistic bazat pe paradigma filtrului Kalman, și pe modelul clotoidal, cu aspectele sale statice și dinamice. Presupunerile obișnuite utilizate de alte metode de detecție și urmărire au putut fi evitate datorită stereoviziunii și a generalității metodei de potrivire a modelului. Algoritmii noștri combină soluții de estimare consacrate cu tehnici noi și cu îmbunătățiri originale, într-un detector robust, potrivit pentru o largă varietate de situații: de la autostradă, la drumuri de țară, și chiar scenarii aproape urbane, rezultatele sunt de la bune la excelente. Metoda

funcționează în timp real, cu mare acuratețe. Condițiile de iluminare pot varia într-o plajă largă, și la fel pot varia rata de achiziție sau viteza de deplasare, și sistemul de urmărire a benzilor va funcționa.

Contribuțiile originale care definesc această soluție sunt:

- Folosirea directă a informației 3D, în locul disparităților din spațiul imagine. Soluția noastră este probabil prima care utilizează datele 3D, în spațiu cartezian.
- Algoritmii pentru detecția unghiului de aplecare și a curbării verticale, care se bazează pe mulțimea punctelor 3D, și țin cont de erorile acestor puncte.
- Metoda de proiecție a suprafeței 3D a benzii în spațiul imagine, ce elimină majoritatea limitelor asociate cu alte metode de proiecție descrise în literatura de specialitate.
- Metoda pentru reconstrucția parametrilor 3D, din rezultatele din spațiul imagine, folosind geometria camerei.
- Algoritmii de detecție a benzilor adiacente, bazat pe informație 3D.

Noutatea și relevanța soluției descrise este dovedită de numărul mare de citări obținute de articolele noastre ([Nedevschi2004c] și [Nedevschi2004d]) din 2004 până în prezent.

Sistemul de detecție a drumului descris în acest capitol constituie un cadru pentru dezvoltarea de diferite îmbunătățiri: diferite metode de extragere a trăsăturilor pot fi încercate, deoarece algoritmul le tratează uniform, sau chiar diferite modele. Acest lucru oferă o bază pentru cercetarea descrisă în capitolul următor: urmărirea benzilor în mediul urban.

## **5.2. Sistem de urmărire a drumurilor urbane, bazat pe stereoviziune și pe filtrul Kalman**

Acest capitol descrie o soluție originală pentru urmărirea drumurilor urbane, care folosește informația oferită de stereoviziune și posibilitățile de urmărire și integrare a informațiilor multiple oferite de filtrul Kalman.

Scenariul urban prezintă provocări noi pentru urmărirea drumului, deoarece geometria benzilor este uneori atipică, traficul auto este mult mai încărcat, cu multe tipuri de obstacole care în mod normal nu se găsesc pe autostradă. Mai mult, cerințele de performanță pentru un asemenea sistem sunt mai mari.

Proiectul DESBOR, început în 2005, a avut ca scop dezvoltarea unui sistem senzorial de timp real pentru mediul urban. Din cauza cerințelor de calitate crescute, procesul de stereoviziune a fost modificat pentru a furniza informații dense, prin utilizarea unui accelerator hardware.

Sistemul de detecție a drumului a fost puțin influențat de noul sistem stereo, deoarece pentru estimarea drumului sunt suficiente muchiile. Pe de altă parte, natura încărcată a traficului urban, vizibilitatea redusă a marcajelor, geometriile nonstandard, au cerut o modificare semnificativă a sistemului.

### **5.2.1. Arhitectura soluției**

Detectorul de bandă urban este organizat ca un integrator de multiple informații, similar cu un sistem de fuziune a informațiilor senzoriale. În loc de a utiliza mai mulți senzori fizici,

avem mai multe etaje de detecție, care furnizează rezultate ce vor fi folosite pentru actualizarea parametrilor modelului. Ciclul începe cu predicția, și se continuă cu toți algoritmi de detecție, până la actualizarea finală. Când un algoritm actualizează starea, rezultatul devine predicție pentru următorul stadiu. Astfel, putem adăuga un număr oricât de mare de algoritmi în lanțul de procesare, sau putem activa sau dezactiva selectiv metode.

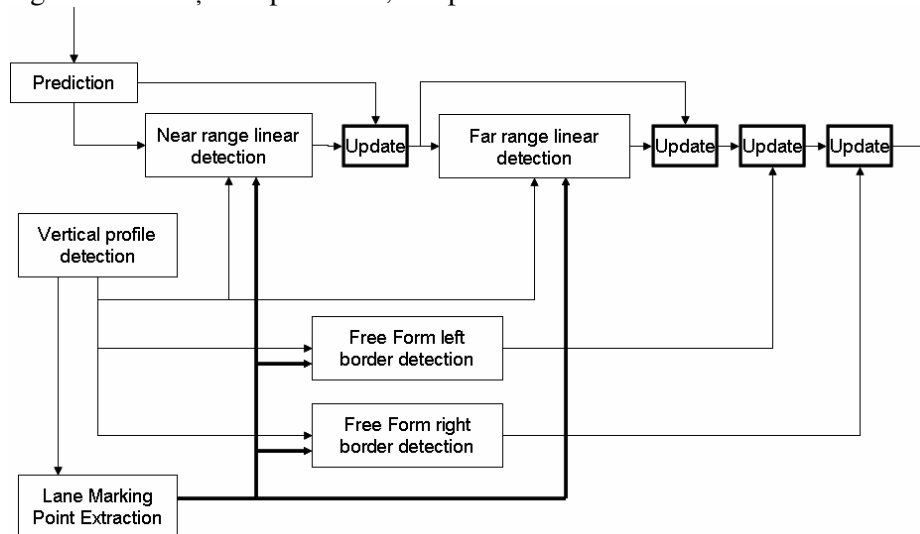


Fig. 5.9. Arhitectura sistemului de urmărire a benzii în mediu urban

Figura 5.9 arată organizarea sistemului de urmărire a benzii, principalele module de procesare și relația dintre ele.

*Predicția* – Acest pas aplică ecuațiile modelului dinamic rezultatelor din estimarea anterioară, folosind parametrii de mișcare ai vehiculului propriu, citiți de pe magistrala CAN. Vectorul de stare prezis, împreună cu matricea lui de covarianță, sunt folosiți pentru a defini zone de căutare.

*Detecția profilului vertical* – Se aplică același algoritm ca în soluția dezvoltată pentru autostradă, ajustat pentru intervalele de distanță din traficul urban. Se selectează apoi punctele aparținând șoselei pentru modulele următoare.

*Extragerea marcajelor* – Împreună cu detecția muchiilor și identificarea trăsăturilor de drum, detecția marcajelor este parte a metodologiei de extracție a trăsăturilor delimitatoare pentru estimarea drumului. Algoritmul detectează marcajele ca perechi de puncte de drum de gradient cu modul similar dar cu semn opus, separate de o distanță predefinită.

*Detecția liniară în domeniul apropiat* – Elementul central al procesului de măsură este potrivirea modelului liniar. Acest algoritm potrivește două segmente la punctele proiectate perspectivă, ținând seama de mai multe constrângeri care asigură că aceste segmente pot reprezenta o bandă validă.

*Detecția liniară în domeniul îndepărtat* – Dacă potrivirea modelului liniar la apropiere reușește, același algoritm se aplică pe o secțiune de distanță mai îndepărtată, pentru a rafina estimarea pe șosele curbate. Dacă avem obstacole pe bandă, acest pas nu se execută.

*Detecția fără constrângeri de model pentru marginea stângă / dreaptă* – Aceste module sunt independente de predicția bazată pe model, dar se bazează pe rezultatele procesului de

extragere a marcajelor. Fiecare margine este estimată independent, ca un lanț de puncte 3D. Rezultatul acestor metode este folosit pentru a actualiza modelul, dar poate fi folosit și ca rezultat independent.

*Actualizare* – Fiecare algoritm de detecție va actualiza parametrii modelului drumului, și matricea de covarianță asociată, utilizând ecuațiile filtrului Kalman extins.

### 5.2.2. Extragerea marcajelor

Cea mai importantă trăsătură a scenariului urban este marcajul rutier, care ne va ghida spre evitarea muchiiilor fără importanță care pot apărea pe suprafața drumului. În absența marcajelor orice muchie este acceptată, dar marcajele vor avea prioritate atunci când există.

Marcajul rutier este de obicei alb, sau de o nuanță mai deschisă decât restul suprafeței drumului. Dacă se parcurge imaginea pe orizontală, intensitatea percepută va varia într-un model specific, întuneric-lumină-întuneric (Dark-Light-Dark, DLD). Tranziția DLD se detectează ca o pereche de gradienti de modul similar și semn opus [Goldbeck1999].

Problema este că efectul de perspectivă afectează nivelul de detaliu din imagine pentru suprafața drumului. Regiunile mai apropiate au o textură mai bogată, iar la depărtare chiar și marcajele bine delimitate sunt abia vizibile. Un gradient calculat cu o mască de dimensiune fixă presupune că nivelul de detaliu în fiecare punct al imaginii este același.

#### 5.2.2.1. Algoritm de detecție a marcajelor

*Calcularea gradientului orizontal cu o mască de dimensiune adaptivă*

Dimensiunea marcajului în imagine se stabilește prin proiectarea unor coordonate ale extremelor unui marcaj mediu în spațiul imagine, și interpolarea, pentru fiecare linie, a lățimii obținute, ținând cont că la linia orizontului lățimea percepută va fi zero. În funcție de lățimea acestui marcaj se va determina lățimea filtrului, care va avea forma generală  $[-1 \ -1 \ \dots \ -1 \ 0 \ 1 \ 1 \ \dots \ 1]$ . Valoarea gradientului orizontal pentru un punct de coordonate  $(x, y)$  este:

$$G_N(x, y) = \frac{\sum_{i=x+1}^{x+D} I(i, y) - \sum_{i=x-1}^{x-D} I(i, y)}{2D} \quad (5.20)$$

$$D = \text{KernelSize}(y)$$

Pentru accelerarea calculelor, ecuația de mai sus poate fi rescrisă recursiv. Dacă notăm gradientul nenormalizat cu lățimea filtrului ca  $G_U$ :

$$G_U(x, y) = \sum_{i=x+1}^{x+D} I(i, y) - \sum_{i=x-1}^{x-D} I(i, y) \quad (5.21)$$

Atunci avem relația recurentă, care va avea timp de procesare fix pentru fiecare linie a imaginii:

$$G_U(x, y) = G_U(x-1, y) + I(x+D, y) - I(x, y) + I(x-D-1, y) - I(x-1, y) \quad (5.22)$$

Normalizarea se aplică la sfârșitul procesării punctelor de pe fiecare linie.

$$G_N(x, y) = \frac{G_U(x, y)}{2D} \quad (5.23)$$



Fig. 5.10. Imaginea originală (stânga) și rezultatul aplicării filtrului cu dimensiune variabilă (dreapta)

După aplicarea filtrului, se elimină valorile intermediare, reținându-se doar minimele și maximele locale. Apoi, pentru fiecare valoare de maxim local se caută corespondentul minim, într-un interval de distanță impus de lățimile acceptabile ale marcajelor și de efectul perspectivă. Valoarea în modul a celor două extreme corespondente trebuie să fie similară.

Până acum procesarea s-a făcut în spațiul imagini, cu ceva informații despre parametrii camerei, care permit calculul perspectivei. Stereoviziunea oferă informație 3D pentru punctele care rămân după alegerea perechilor, și astfel se pot elimina perechile care nu corespund suprafeței drumului.



Fig. 5.11. Marcajele, validate de stereoviziune.

### 5.2.3. Potrivirea modelului benzilor prin drepte

Într-un domeniu de distanță suficient de scurt, geometria drumului poate fi aproximată prin segmente de dreaptă. Dreptele din imagine pot fi detectate folosind metode standard, și vor trebui să se supună unui set de constrângeri pentru a putea fi considerate proiecțiile unei benzi de circulație 3D. Aceste constrângeri sunt următoarele: dreptele trebuie să fie paralele în spațiul 3D, deci trebuie să se intersecteze în punctul de fugă al imaginii 2D; trebuie să formeze benzi nu prea late, nici prea înguste, și banda rezultată trebuie să conțină vehiculul propriu.

### 5.2.3.1. Definirea regiunilor de căutare

După ce profilul vertical este detectat, se transformă predicția stării ( $\bar{\mathbf{X}}_i, \bar{\mathbf{P}}_i$ ) în predicția măsurătorilor ( $\bar{\mathbf{X}}_{D,i}, \bar{\mathbf{P}}_{D,i}$ ), folosind metoda de proiecție descrisă în capitolul 5.1. Vectorul  $\mathbf{X}_D$  are forma  $\mathbf{X}_D = (x_{1L}, x_{2L}, \dots, x_{nL}, x_{1R}, x_{2R}, \dots, x_{nR})$ . Matricea de covarianță a lui  $\bar{\mathbf{X}}_D$  se obține prin ecuația:

$$\bar{\mathbf{P}}_D = \mathbf{J}_M \bar{\mathbf{P}} \mathbf{J}_M^T + \mathbf{R}_D \quad (5.24)$$

Unde  $\mathbf{J}_M$  este Jacobianul funcției de transformare.

Pentru detecția liniară, avem nevoie doar de două coordonate consecutive  $x$  (un singur segment). De exemplu, vectorul de măsură pentru cea mai apropiată regiune de distanță arată astfel:

$$\bar{\mathbf{Y}} = \begin{bmatrix} \bar{\mathbf{X}}_D(1) \\ \bar{\mathbf{X}}_D(2) \\ \bar{\mathbf{X}}_D(n+1) \\ \bar{\mathbf{X}}_D(n+2) \end{bmatrix} \quad (5.25)$$

Jacobianul asociat cu acest vector, pe care îl notăm cu  $\mathbf{H}$ , este o sub-matrice a jacobianului întreg  $\mathbf{J}_M$ .

$$\mathbf{H} = \begin{bmatrix} \mathbf{J}_M(1,1\dots 9) \\ \mathbf{J}_M(2,1\dots 9) \\ \mathbf{J}_M(n+1,1\dots 9) \\ \mathbf{J}_M(n+2,1\dots 9) \end{bmatrix} \quad (5.26)$$

Matricea de covarianță a măsurătorii prezise este o sub-matrice a lui  $\bar{\mathbf{P}}_D$ . Vectorul  $\bar{\mathbf{Y}}$  și matricea  $\bar{\mathbf{P}}_Y$  definesc zonele de căutare pentru faza de detecție.



Fig. 5.12. Regiunile de căutare, pentru distanța apropiată.

### 5.2.3.2. Extragerea dreptelor

Primitivele pentru metoda de potrivire a modelului sunt dreptele, și de aceea avem nevoie de o metodă care să extragă aceste drepte pe baza punctelor de drum. Metoda clasică este

transformata Hough. În forma clasică, această transformată reprezintă dreapta prin parametrul distanță față de origine  $\rho$  și orientare  $\theta$ . Deoarece o dreaptă de tip delimitator va intersecta regiunea de căutare în două puncte, unul la limita de sus și unul la limita de jos, iar coordonatele  $y$  ale acestor puncte sunt cunoscute, fiind fixe, o dreaptă poate fi definită prin perechea de coordonate  $x$ .

$Line(i) = \{x_{top}(i), x_{bottom}(i)\}$

Varianta noastră de transformată Hough va folosi cele două coordonate ca parametri ai liniei. Procesul de găsimă a liniilor este următorul:

*Algoritmul de detecție a dreptelor:*

Pentru fiecare posibil  $x_{bottom}$

Pentru fiecare punct din regiunea de căutare având coordonatele  $(x,y)$

Se calculează intersecția dintre linia formată de punctele  $(x_{bottom}, y_{bottom})$ - $(x,y)$  cu limita superioară definită de  $y_{top}$ :

$$x_{top} = x_{bottom} + \frac{(x - x_{bottom})}{y - y_{bottom}}(y_{top} - y_{bottom}) \quad (5.27)$$

Se calculează valorile discrete pentru  $x_{top}$ , și se adaugă o valoare  $fWeight$  la o poziție  $x_{top}$  dintr-o histogramă asociată.

Se parcurge histograma, și se găsește poziția maximului,  $max_{postop}$ , și valoarea acestuia,  $max_{value}$ . Se elimină orice altă dreaptă care trece prin  $x_{bottom}$ .

$fWeight$  este ponderea asociată cu fiecare punct, dată de clasa punctului (marcajele au pondere mai mare).

Rezultatul algoritmului de mai sus este o mulțime de drepte. Pentru fiecare poziție  $x_{bottom}$  avem o poziție unică a lui  $x_{top}$  ( $max_{postop}$ ) și cunoaștem numărul de puncte al acestei drepte,  $npoints$ . Vom redefini reprezentarea liniei ca

$Line(x_{bottom}) = \{x_{top}(x_{bottom}), npoints(x_{bottom})\}$

$x_{bottom}$  nu mai este un parametru, ci un index. Dacă nu avem drepte care să treacă prin  $x_{bottom}$ , se va marca o valoare nulă la  $npoints$ . Spațiul de căutare se reduce din nou, din spațiul bidimensional al parametrilor am ajuns la un spațiu unidimensional.

### 5.2.3.3. Găsirea celei mai bune perechi de drepte

Algoritmul pentru identificarea celei mai bune perechi este următorul:

Inițializarea  $MaxWeight = 0$

Pentru fiecare dreaptă  $L_L$  din mulțimea stângă

Pentru fiecare dreaptă  $L_R$  din mulțimea dreaptă

Dacă  $(L_L)$  nu este valid, continuă

Dacă  $(L_R)$  nu este valid, continuă

Dacă perechea  $(L_L, L_R)$  nu este validă, continuă

$Weight = ComputeWeight(L_L, L_R)$

Dacă  $(Weight > MaxWeight)$

$MaxWeight = Weight$

$BestPair = (L_L, L_R)$

Dacă  $MaxWeight > 0$  returnează  $BestPair$

#### Validarea dreptelor individuale

O dreaptă este validă dacă are un număr de puncte mai mare decât un prag T, care este:

$$T = \frac{\sqrt{(y_{top} - y_{bottom})^2 + (x_{top} - x_{bottom})^2}}{5} \quad (5.28)$$

#### Validarea perechilor de drepte

Dacă dreptele individuale sunt valide, următorul pas este validarea perechilor. Se testează poziția laterală și lățimea potențială a benzii create de cele două drepte, iar acești parametri trebuie să fie în limite acceptabile. O altă condiție de validitate este intersecția acestor drepte aproape de linia orizontului, dată de profilul vertical. Acest lucru indică paralelismul în spațiul 3D.

#### Calcularea ponderii (importanței) perechii de drepte

Calcularea ponderii perechilor este cea mai importantă parte a procesului de potrivire liniară a modelului. Trebuie definită o funcție care va fi maximă atunci când

- Numărul de puncte de pe fiecare dreaptă este mare
- Lățimea benzii este aproape de cea ideală
- Poziția laterală a benzii este apropiată de centrul de referință

Funcția este un produsul a trei factori:

$$Weight = W_{Edge} W_{Width} W_{Lateral} \quad (5.29)$$

$W_{Edge}$  este cauzat de numărul de puncte de pe drepte:

$$W_{Edge} = \frac{npoints(L_L)}{D(L_L)} + \frac{npoints(L_R)}{D(L_R)} \quad (5.30)$$

Unde  $D$  este lungimea segmentului:

$$D(L) = \sqrt{(y_{top} - y_{bottom})^2 + (x_{top}(L) - x_{bottom}(L))^2} \quad (5.31)$$

Ceilați factori sunt:

$$W_{Width} = 1 - \frac{|Width - IdealWidth|}{IdealWidth} \quad (5.32)$$

$$W_{Lateral} = 1 - \frac{|xcenter - imagemiddlex|}{maximumwidth} \quad (5.33)$$

Perechea cu ponderea combinată maximă este aleasă ca rezultat final.






Fig. 5.13. Rezultatul final al detecției prin linii

#### 5.2.4. Actualizarea parametrilor modelului benzii folosind rezultatele detecției liniare

Detecția segmentelor de dreaptă delimitatoare se poate încheia în patru feluri posibile: ambele margini sunt detectate (LR), marginea stângă este detectată (L), marginea dreaptă este detectată (R) sau nici o margine nu este detectată (eșec). Primele trei variante pot fi folosite pentru a actualiza vectorul de stare, folosind ecuațiile filtrului Kalman extins. Pentru acest proces avem nevoie de următorii vectori și matrice:

$\mathbf{Y}$  – vectorul de măsură

$\bar{\mathbf{Y}}$  – vectorul de măsură prezis

$\mathbf{H}$  – linearizarea funcției de măsură (Jacobianul)

$\mathbf{R}$  – matricea de covarianță a zgomotului asociat măsurătorii

Acești parametri depind de situația în care ne aflăm. Pentru cazul în care ambele segmente sunt detectate, avem

$$\mathbf{Y} = \begin{bmatrix} x_{bottomleft} \\ x_{toleft} \\ x_{bottomright} \\ x_{topright} \end{bmatrix} \quad (5.34)$$

$$\bar{\mathbf{Y}} = \begin{bmatrix} \bar{\mathbf{X}}_D(1) \\ \bar{\mathbf{X}}_D(2) \\ \bar{\mathbf{X}}_D(n+1) \\ \bar{\mathbf{X}}_D(n+2) \end{bmatrix} \quad (5.35)$$

$$\mathbf{H} = \begin{bmatrix} \mathbf{J}_M(1,1...9) \\ \mathbf{J}_M(2,1...9) \\ \mathbf{J}_M(n+1,1...9) \\ \mathbf{J}_M(n+2,1...9) \end{bmatrix} \quad (5.36)$$

$$\mathbf{R} = \begin{bmatrix} \sigma_d^2 & 0 & 0 & 0 \\ 0 & \sigma_d^2 & 0 & 0 \\ 0 & 0 & \sigma_d^2 & 0 \\ 0 & 0 & 0 & \sigma_d^2 \end{bmatrix} \quad (5.37)$$

$\sigma_d$  este un parametru care exprimă gradul de incertitudine al detecției în spațiul imagine. Ecuațiile filtrului Kalman extins se vor aplica pentru oricare situație:

$$\mathbf{K} = \bar{\mathbf{P}}(k)\mathbf{H}^T(\mathbf{R} + \mathbf{H}\bar{\mathbf{P}}\mathbf{H}^T)^{-1} \quad (5.38)$$

$$\mathbf{X} = \bar{\mathbf{X}} + \mathbf{K}(\mathbf{Y} - \bar{\mathbf{Y}}) \quad (5.39)$$

$$\mathbf{P} = (\mathbf{I} - \mathbf{KH})\bar{\mathbf{P}}(\mathbf{I} - \mathbf{KH})^T + \mathbf{K}\mathbf{R}\mathbf{K}^T \quad (5.40)$$

După ce starea benzii este actualizată prin folosirea măsurătorilor de tip segment de dreaptă în zona de apropiere, se generează noi regiuni de căutare pentru o zonă de distanță mai îndepărtată, și se repetă procesul, pentru rafinarea mai bună a parametrilor în cazul unui drum curbat.

### 5.2.5. Inițializarea și re-inițializarea procesului de urmărire

Procesul de urmărire a benzii este foarte vulnerabil la date greșite în faza de inițializare. Spațiul de căutare este foarte larg, cu multe trăsături din care se poate alege o posibilă bandă. Problema este că alegerea greșită va restricționa căutările ulterioare în aceleași regiuni, împiedicând revenirea. Pentru a preveni aceste probleme, vom efectua mai multe detecții pornind de la aceleași condiții inițiale, iar dacă aceste detecții vor avea rezultate similare, se va inițializa un proces de urmărire.

După ce urmărirea este inițializată, starea benzii va fi actualizată în mod constant cu rezultatele diferitelor metode de detecție. Procesul poate continua atâta timp cât nici o margine a drumului nu rămâne neactualizată pentru un interval lung de timp.

### 5.2.6. Detecția marginilor benzii fără constrângeri de model

Uneori constrângerile modelului nu sunt suficient de adaptabile pentru a reprezenta orice situație din realitate. Pentru acest caz am dezvoltat o metodă de extragere a curbelor delimitatoare ale benzii care va detecta fiecare margine în parte, pe baza celor mai relevante trăsături, marcajele rutiere.

#### 5.2.6.1. Pregătirea datelor

Se vor lua în considerare punctele de marcaj, în spațiul 3D, proiectate în planul XOZ. Pe baza acestor puncte se va construi o grilă cu celule care vor fi ocupate sau libere, în funcție de prezența sau absența punctelor de marcaj. Această matrice de celule va deveni o imagine binară, care va fi supusă apoi transformării de distanță. Imaginea de distanță permite calcularea distanței de la o curbă la marcaje prin simpla însumare a pixelilor din imagine care sunt acoperiți de respectiva curbă.

#### 5.2.6.2. Potrivirea marginii la datele derivate din marcaje

Marginea drumului este reprezentată ca o curbă de tip Catmull-Rom spline, o interpolare continuă a unui set de puncte de control. Pentru găsirea curbei, vom găsi punctele de control, cum se vede în imaginea de mai jos:




Fig. 5.14. Definirea problemei de căutare pentru curba Catmull-Rom.

Se va căuta mulțimea de puncte de control care minimizează distanța de la curbă la imaginea dată de marcaje. Pentru căutare se va folosi algoritmul Metropolis, în modul descris în [Kluge1995].

### 5.2.7. Actualizarea stării benzii folosind rezultatele detecției fără constrângeri de model

Pentru a actualiza parametrii stării, avem nevoie de elementele care sunt implicate în ecuațiile filtrului Kalman extins.

Specific, avem nevoie de vectorul de predicție a măsurii,  $\bar{\mathbf{Y}}_i$ , de vectorul de măsură  $\mathbf{Y}$ , de matricea de măsură  $\mathbf{H}$  și de covarianța erorilor de măsură  $\mathbf{R}$ . Vom defini o funcție care transformă starea benzii în șirul de puncte care definește marcajul liber de model, și folosim această funcție pentru calcularea predicției măsurătorii.

$$\bar{\mathbf{Y}}_i = \text{FreeFormMapping}(\bar{\mathbf{X}}_i, S)$$

$$\text{FreeFormMapping}(\bar{\mathbf{X}}_i, S) = [X_S(Z_1), X_S(Z_2), \dots, X_S(Z_N)]^T$$

Prin  $S$  notăm marginea care va fi actualizată, stânga sau dreapta.

Vectorul de măsură  $\mathbf{Y}$  va conține coordonatele  $X$  pentru distanțe  $Z$  fixe.  
 $\mathbf{Y} = [X_1, X_2, \dots, X_n]^T$ .

Matricea de covarianță a măsurătorii va defini incertitudinea acesteia, și valorile ei vor fi derivate din distanța minimă rezultată în urma procesului de căutare.

Matricea de măsură  $\mathbf{H}$  este linearizarea procesului de transformare a stării în reprezentarea liberă de model.

$$H[i, j] = \frac{\partial \text{FreeFormMapping}[i](\bullet, S)}{\partial \mathbf{X}[j]}(\bar{\mathbf{X}}) \quad (5.41)$$

În acest moment există toate elementele pentru a se putea aplica filtrul Kalman.

### 5.2.8. Teste și rezultate

Sistemul de detecție a benzilor pentru mediul urban a fost testat în mai multe situații de trafic real: un scenariu controlat într-un poligon special, și două scenarii necontrolate, unul în Germania, Wolfsburg, și unul în România, la Cluj-Napoca. Am identificat mai multe elemente de dificultate:

- Trafic aglomerat
- Delimitare incompletă a benzii – absența temporară sau permanentă a delimitatorilor.
- Curburi mari
- Geometrii complexe
- Vizibilitate slabă a delimitatorilor drumului
- Trăsături zgomotoase pe șosea, care pot fi confundate cu delimitatori.
- Condiții generale de vizibilitate proaste (ploaie, ceață, fum)

Primul test este în situații cu vizibilitate rezonabilă, trafic mediu spre încărcat, și marcaje destul de bine vizibile. Exemple de rezultate sunt arătate în figura 5.15.




Fig. 5.15. Trafic urban cu geometrie standard a benzilor, obstacole prezente, și calitate slabă a delimitatorilor.

Detectorul de bandă s-a comportat adecvat în situații cu curbură strânsă (rază de curbură sub 40 m), sau în cazul geometriilor nestandard. Următoarele imagini arată câteva exemple de acest gen.




Fig. 5.16. Situații cu curbură mare și geometrii nestandard.

Detectorul de bandă a fost testat și dovedit funcțional și în situațiile în care drumul conține multiple trăsături care ar putea fi confundate cu marcajele, sau când delimitatoarele sunt dificil de văzut. Sistemul a funcționat chiar și atunci când parbrizul a fost parțial acoperit cu apă de ploaie.



Fig. 5.17. Multiple trăsături de tip zgomot pe suprafața drumului, și vizibilitate slabă.

Figura 5.18 arată mai multe rezultate ale detecției marginilor fără constrângerile de model, utilizată ca detector independent.




Fig. 5.18. Detecția marginilor independent de model, în mai multe situații.

### 5.2.9. Concluzii

Urmărirea benzilor de circulație în mediul urban este o problemă dificilă și complexă. Dificultatea apare încă dinainte de a începe căutarea unei soluții, pentru că trebuie să ne întrebăm ce anume vrem să detectăm. Există multe trăsături, marcaje, delimitatori, linii de ghidare, intersecții, care pot fi detectate, dar ce facem apoi cu ele? Putem să pierdem timp de procesare pentru orice trăsătură care se găsește în trafic? Ne permitem să ne complicăm cu o infinitate de modele, sau va trebui să lucrăm fără un model, doar pentru că vrem să acoperim toate posibilitățile?

Scopul nostru este construirea unui sistem funcțional, în timp real, care să urmărească drumul urban. Uneori putem uita că detecția benzii înseamnă de fapt detecția unui culoar prin care putem naviga. Asta înseamnă că indiferent de câte delimitatoare avem, scopul nostru este să detectăm un culoar. Uneori acest culoar este bine delimitat, uneori avem prea multe delimitatoare și trebuie să facem o selecție, și uneori culoarul este doar parțial delimitat, și trebuie să facem presupuneri, dar rezultatul final este un culoar: orientat, curbat, de o lățime specificată, care să indice viitoarea traiectorie a vehiculului.

Sperăm că am reușit să creăm un sistem care satisface cerințele pe care le-am reamintit mai sus. Algoritmul a fost testat în multiple situații, unele de dificultate ridicată, și a funcționat bine în majoritatea timpului, dovedindu-și valoarea ca sistem de asistență a conducerii auto în oraș.

Contribuțiile originale care definesc această soluție de urmărire sunt:

- Algoritmul de detecție a marcajelor rutiere, care combină un filtru diferențiator de lățime variabilă cu o metodă de căutare a corespondențelor care ține seama de efectul de perspectivă, și folosește informația 3D oferită de stereoviziune pentru validarea rezultatelor.

- Arhitectura cadru a sistemului de urmărire a benzilor de circulație, care are ca element o stare descrisă de un model unic, dar permite utilizarea informațiilor eterogene pentru actualizare, fuzionând aceste informații când și dacă ele sunt disponibile.
- Algoritmii de potrivire prin linii a modelului drumului, care folosește îmbunătățiri pentru accelerarea transformatei clasice Hough.
- Detecția marginilor benzii fără constrângerea modelului, și fuzionarea acestor rezultate cu starea descrisă de model.

### 5.3. Sistem de urmărire a benzilor în situații dificile folosind filtrul bazat pe particule

Soluțiile robuste pentru urmărire sunt bazate pe metode probabilistice, care folosesc modele pentru a contracara posibilele zgomote în datele de măsură. În mod tradițional, implementarea acestor tehnici se face prin filtrul Kalman, care are avantajul de a reduce spațiul de căutare și de a crește stabilitatea rezultatelor. Rezultatele prezentate în capitolele 5.1 și 5.2 sunt dovadă că filtrul Kalman este o tehnică versatilă, utilizabilă în multiple forme, și care poate asigura soluții de timp real.

Caracteristicile care fac din filtrul Kalman o soluție elegantă și eficientă sunt aceleași caracteristici care pot cauza probleme când drumul nu este continuu. Viraje strânse, schimbări de bandă, geometrii atipice ale drumului, sunt situații care pun probleme unui sistem care reprezintă starea ca o densitate de probabilitate Gaussiană, și care restricționează spațiul de căutare în jurul stărilor prezise.

Filtrul bazat pe particule este o tehnologie aplicată mai recent în urmărirea benzilor, această tehnologie permițând menținerea mai multor ipoteze, utilizarea unor măsurători mai simple, și abordarea mai rapidă a discontinuităților. Acest capitol va descrie un sistem de detecție și urmărire a benzilor care combină avantajele filtrului bazat pe particule, ale stereoviziunii și ale procesării imaginilor de intensitate, pentru a obține rezultate robuste în situații dificile din oraș, de pe autostradă, și de pe drumurile rurale.

#### 5.3.1. Modelarea stării

În soluțiile anterioare, descrise în capitolele 5.2 și 5.3, densitatea de probabilitate a stării a fost descrisă de o funcție Gaussiană, definită de valoarea medie și de matricea sa de covarianță. O caracteristică a filtrului de particule este că acesta poate folosi orice fel de funcție de probabilitate. În acest caz, densitatea de probabilitate pentru starea drumului este descrisă la un timp  $t$  de o mulțime de  $N$  particule  $p(\mathbf{x}) \approx \{\mathbf{x}_t^i, \pi_t^i, i = 1 \dots N\}$ , fiecare având o pondere. Ponderile vor fi normalizate pentru ca suma lor să fie întotdeauna 1. Fiecare valoare  $\mathbf{x}$  este o ipoteză asupra stării drumului, în forma unui vector de parametri, care conține informații despre geometria 3D a drumului.

Scopul algoritmului filtrului bazat pe particule este să estimeze valorile  $\mathbf{x}_t^i$  și ponderile  $\pi_t^i$  folosind informația 3D oferită de stereoviziune, împreună cu muchiile din imagini, și cu modelul dinamic al benzii și al vehiculului.

### 5.3.2. Vedere de ansamblu asupra soluției

Sistemul estimează continuu starea drumului pe baza particulelor. Nu există fază de inițializare, și fiecare ciclu este executat în același fel, cum este descris în figura de mai jos. Ciclul începe cu faza de re-eșantionare a particulelor, care se bazează în parte pe particulele estimate anterior, și în parte pe particule complet aleatoare, extrase din tot potențialul spațiu de căutare, pentru a putea trata o nouă ipoteză dacă aceasta apare.

Faza următoare, *deplasarea deterministă*, este aplicată tuturor particulelor, folosind parametrii de mișcare ai vehiculului. Pasul următor este *difuzia stohastică*, ce alterează valoarea particulelor cu mici cantități aleatoare, ce țin cont de posibilele devieri ale realității de la model.

Detecția unghiului de aplecare este efectuată independent, folosind tot o abordare probabilistică. Valoarea unghiului detectat este folosită pentru a alege trăsăturile de drum care vor fi folosite pentru a *pondera particulele* în faza de măsură.

Pasul de *validare* este asigură că particulele urmăresc cu adevărat o bandă, iar dacă acest pas are succes se va efectua *estimarea*.

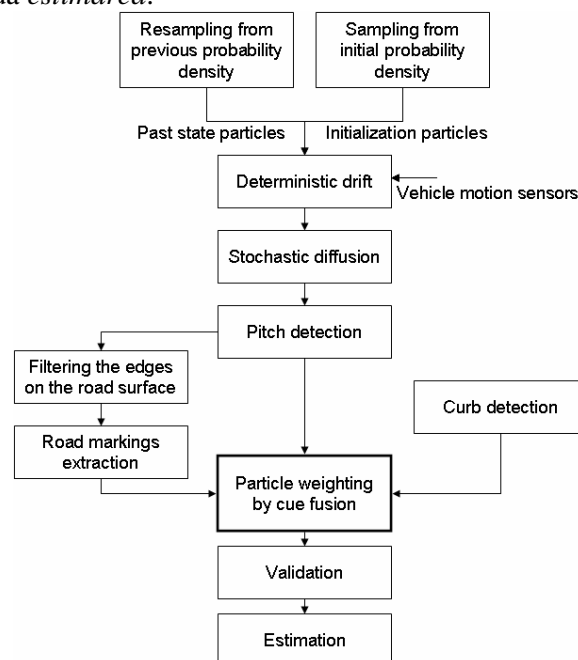


Fig. 5.19. Urmărirea folosind filtre bazate pe particule – vedere de ansamblu

### 5.3.3. Predicția – re-eșantionare, deplasare, difuzie

Sarcina predicției este de a deriva o densitate de probabilitate aproximativă pentru drum la timpul  $t$  știind situația la timpul  $t-1$  și modelul dinamic. Înainte ca predicția să poată fi aplicată, starea anterioară descrisă de mulțimea  $\{\mathbf{x}_t^i, \pi_t^i, i = 1 \dots N\}$  trebuie să fie re-eșantionată în particule de pondere egală. Re-eșantionarea se realizează prin efectuarea de  $N$  extrageri aleatoare din densitatea de probabilitate descrisă de ponderi. O particulă cu o pondere mai mare va fi extrasă de mai multe ori, iar o particulă de pondere mai mică de mai puține ori, sau deloc. În teorie, densitatea de probabilitate descrisă ar trebui să nu se schimbe.

$$\{\mathbf{x}_{t-1}^i, \pi_{t-1}^i, i=1 \dots N\} \xrightarrow{\text{resampling}} \{\hat{\mathbf{x}}_{t-1}^i, \frac{1}{N}, i=1 \dots N\} \quad (5.42)$$

O fracțiune  $R=0.1 N$  va fi aleasă dintr-o distribuție uniformă care acoperă tot spațiul parametrilor drumului. Aceste particule țin cont de posibilitatea ca noi ipoteze, complet independente de predicție, să apară.

Fiecare particulă din mulțimea re-eșantionată va fi supusă procesului de deplasare deterministă, care aplică ecuațiile modelului dinamic fiecărui vector valoare a particulei, și unui efect de difuzie stohastică, ce adaugă o cantitate aleatoare  $\mathbf{w}_t$  extrasă dintr-o probabilitate Gaussiană ce descrie incertitudinea tranziției stărilor.

$$\bar{\mathbf{x}}_t^i = \mathbf{F}_t \hat{\mathbf{x}}_{t-1}^i + \mathbf{B}_t e_t + \mathbf{w}_t \quad (5.43)$$

În acest moment particulele fără pondere (sau cu pondere egală) și valoare  $\bar{\mathbf{x}}_t^i$  sunt pregătite pentru procesul de măsură.

#### 5.3.4. Detecția unghiului de aplecare

Unghiul de aplecare are un comportament mai puțin predictibil, spre deosebire de ceilalți parametri. Acest unghi este influențat de accelerări și decelerări bruște, sau de imperfecțiuni ale drumului. Astfel, vom determina acest parametru independent, și vom folosi această valoare introdusă direct în vectorul de stare al fiecărei particule.



Fig. 5.20. O scenă complexă, de trafic urban, și vederea din lateral a punctelor 3D. Se evidențiază domeniul de valori pentru unghiul de aplecare.

Pentru detecția acestui unghi, vom folosi un algoritm bazat pe histograme, similar cu cel descris în capitolul 5.1, dar la care vom adăuga unele îmbunătățiri substanțiale. Algoritmul pentru construcția histogramei polare este următorul:

Inițializarea histogramei polare  $H(index)$  cu 0, pentru fiecare index

**Pentru** fiecare punct 3D  $p$

Dacă  $distance(p) > Limit$  nu se ia în considerare

Se găsește unghiul dreptei care trece prin  $p$  și prin origine



$$\alpha_p = \tan^{-1} \frac{\text{height}(p)}{\text{distance}(p)} \quad (5.44)$$

Dacă  $\alpha_p > 2^\circ$  or  $\alpha_p < -2^\circ$  nu se ia în considerare

Se găsește indexul lui  $\alpha_p$  din histograma polară

$$\text{index}_p = \frac{\alpha_p + 2^\circ}{0.1^\circ}$$

Se incrementează histograma polară

$$H(\text{index}_p) = H(\text{index}_p) + \frac{\text{distance}(p)^2}{K} \quad (5.45)$$

### Sfârșit

Diferența față de metoda anterioară este metoda de procesare a histogramei. Pentru metoda curentă, vom aborda o metodă probabilistică, însemnând că pentru fiecare candidat pentru unghiul de aplecare  $\alpha_{\text{index}}$  vom aproxima  $p(\alpha = \alpha_{\text{index}})$  pe baza informației disponibile.

Prima presupunere este că valoarea unghiului de aplecare nu depinde de trecut, natura acestuia fiind imprevizibilă.

$$p(\alpha | y_1, y_2, \dots, y_t) = p(\alpha | y_t) \quad (5.46)$$

A doua presupunere este că nu există informații a priori, deci tot ce ne interesează este verosimilitatea măsurătorilor.

$$p(\alpha | y_t) \propto p(y_t | \alpha) \quad (5.47)$$

Această verosimilitate este combinarea a două indicii, derivate din două postulate:

- Punctele de pe drum, în proiecție laterală, sunt aproape colineare
- Majoritatea punctelor 3D din scenă sunt deasupra șoselei.

Primul indice are verosimilitatea proporțională cu valoarea histogramei  $H$ , iar al doilea are verosimilitatea proporțională cu histograma cumulativă derivată din cea polară,  $CH$ .

$$p(y_H | \alpha = \alpha_{\text{index}}) \propto H(\text{index}) \quad (5.48)$$

$$p(y_{CH} | \alpha = \alpha_{\text{index}}) \propto CH(\text{index}) \quad (5.49)$$

$$p(\alpha = \alpha_{\text{index}} | y_t) \propto H(\text{index})CH(\text{index}) \quad (5.50)$$

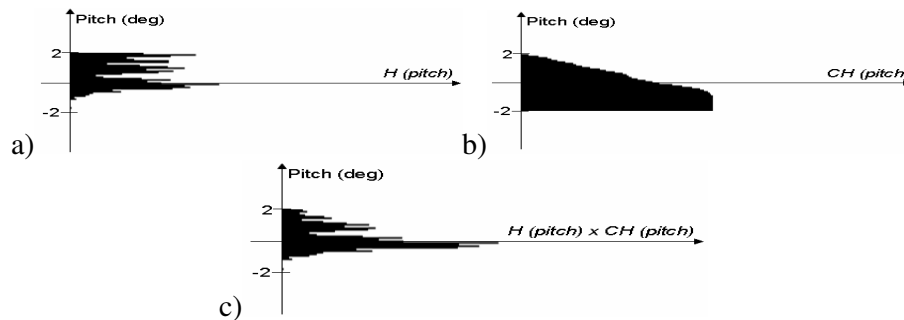


Fig. 5.21. Combinarea indicilor pentru unghiul de aplecare: a) histograma polară, b) histograma cumulativă, c) combinarea indicilor

Unghiul candidat cu cea mai mare verosimilitate combinată a măsurătorilor este ales ca valoarea estimată. Acest unghi este introdus în vectorii particulelor prezise, și este folosit pentru a alege trăsăturile de drum dintre punctele 3D.

### 5.3.5. Proiecția particulelor în spațiul măsurătorilor

Procesul de măsură va fuziona mai multe indicii, obținute prin compararea particulelor cu datele senzoriale. Aceste comparații sunt efectuate în spațiul imagine. Pentru fiecare valoare a particulei, de forma  $\bar{x}_i^i = (W_0, C_H, W_1, C_V, Y_0, X_{CW}, \alpha, \gamma, \psi, W_L, W_R)^T$ , este generat un nou vector,  $\bar{y}_{2D,i}^i = (v_1, \dots, v_P, u_{LI,1}, \dots, u_{LI,P}, u_{RI,1}, \dots, u_{RI,P}, u_{LO,1}, \dots, u_{LO,P}, u_{RO,1}, \dots, u_{RO,P})$ . Valorile  $v$  sunt coordonate ale liniilor din imagine, iar valorile  $u$  sunt coordonate ale coloanelor. Pentru obținerea vectorului  $\bar{y}_{2D,i}^i$  din  $\bar{x}_i^i$ , se parcurg următorii pași:

- Generarea a  $P$  puncte în spațiul 3D, pentru fiecare delimitator al benzii. Aceste puncte sunt egal depărtate pe axa de distanță ( $Z$ ).
- Proiecția acestor puncte în spațiul imagine, folosind parametrii camerei.




Fig. 5.22. Pentru fiecare delimitator (stâng sau drept) se generează puncte 3D egal depărtate, apoi aceste puncte sunt proiectate în spațiul imagine.

- Se intersectează segmentele obținute prin unirea acestor puncte cu linii egal depărtate în spațiul imagine. Punctele de intersecție, egal depărtate în spațiul imagine, reprezintă vectorul  $\bar{y}_{2D,i}^i$ .




Fig. 5.23. Linii orizontale egal depărtate intersectează segmentele obținute prin proiecția punctelor 3D de pe margini.

### 5.3.6. Datele de măsură

Procesul de măsură compară valoarea particulei, proiectată în spațiul imagine prin vectorul  $\bar{y}_{2D,i}^i$  cu mai multe indicii vizuale. Pentru fiecare comparație se calculează o pondere, și în final ponderile se combină prin multiplicare.

Avem trei tipuri de indicii: muchiile de pe suprafața drumului, marcajele și bordurile.

a) Muchiile de pe drum – acestea sunt cele mai de bază informații despre banda de circulație. Imaginea formată de muchiile de pe drum este supusă transformării de distanță, și o imagine de distanță  $DT^E$  este rezultatul obținut.

b) Marcajele și bordurile – majoritatea benzilor sunt delimitate de marcaje sau de borduri. Marcajele sunt extrase folosind algoritmul descris în capitolul 5.2.3, iar marcajele sunt extrase prin procesarea unei hărți dense de înălțimi, cu metoda descrisă în [Oniga2007]. Ambele trăsături au aceeași importanță în algoritmul nostru, și de aceea vor fi tratate împreună. O imagine de distanță  $DT^S$  (Distance Transform – Special Delimiters) este obținută.




Fig. 5.24. Indicii în spațiul imagine: a) imaginea originală de intensitate, b) muchiile corespunzătoare punctelor 3d de pe suprafața drumului, c) marcaje și borduri. Se arată imaginea de distanță asociată acestor indicii

### 5.3.7. Calcularea ponderilor pe baza măsurătorilor

Densitatea a priori fiind codificată în distribuția particulelor în spațiul stărilor, este momentul să se calculeze densitatea posterioară, care va codifica starea după procesul de măsurătoare. Acest lucru este realizat prin calcularea ponderilor pentru particulele prezise.

$$\pi_t^i = p(\mathbf{y}_t | \mathbf{x}_t = \mathbf{x}_t^i) \quad (5.51)$$

Verosimilitatea măsurătorilor este obținută prin înmulțirea verosimilităților indicilor descrise în secțiunea anterioară, verosimilitatea muchiilor și verosimilitatea delimitatorilor speciali.

$$p(\mathbf{y}_t | \mathbf{x}_t = \mathbf{x}_t^i) = p(\text{road\_edges} | \mathbf{x}_t = \mathbf{x}_t^i) \cdot p(\text{mark\_curb} | \mathbf{x}_t = \mathbf{x}_t^i) \quad (5.52)$$

Ambele verosimilități sunt calculate în același mod, aplicând același algoritm pentru imaginile de distanță  $DT^E$  și  $DT^S$ . În mod ideal, proiecția marginilor benzii se va suprapune exact peste muchii. De asemenea, suprafața dintre margini ar trebui să fie liberă de muchii. Pentru a testa aceste două ipoteze, vom folosi două mulțimi de puncte de control: punctele de pe margine, și punctele care sunt în apropierea marginii, dar în interiorul benzii, ca în figura următoare.




Fig. 5.25. Puncte pozitive și negative. Punctele pozitive sunt cele de pe marginea benzii, iar cele negative sunt în interior.

Ecuțiile pentru calcularea verosimilității sunt aceleași pentru cele două indicii. De aceea vom nota, în cele ce urmează, cu  $M$  „metoda”.  $M$  poate fi  $E$  (muchii) sau  $S$  (delimitatori speciali).

Punctele pozitive vor genera distanța pozitivă.

$$D^M(+)=\frac{\sum DT^M(u^+,v^+)}{2P} \quad (5.53)$$

Pentru punctele negative se calculează o distanță complementară.

$$D^M(-)=\frac{\sum (255-DT^M(u^-,v^-))}{2P} \quad (5.54)$$

Cele două distanțe se combină prin mediere ponderată, cu o pondere mai mare dată distanței pozitive.

$$D^M=\frac{\alpha D^M(+)+\beta D^M(-)}{(\alpha+\beta)} \quad (5.55)$$

Pentru fiecare metodă  $M$  se calculează verosimilitatea folosind o funcție Gaussiană pentru a transforma distanța în valoare de probabilitate.

$$p(M|\mathbf{x}_i=\mathbf{x}_i^i)=\frac{1}{\sigma_M\sqrt{2\pi}}e^{-\frac{(D^M)^2}{2\sigma_M^2}} \quad (5.56)$$

Verosimilitățile vor fi combinate prin multiplicare, iar rezultatul este atașat ca pondere fiecărei particule. Se va efectua și o validare pentru fiecare particulă, iar dacă banda descrisă de această particulă este degenerată (prea îngustă, prea largă, prea departe de poziția noastră) ea va primi pondere zero.

După ce fiecare particulă trece prin procesul de măsură, ponderile se re-normalizează pentru ca suma lor să fie 1.

### 5.3.8. Estimarea și validarea drumului

Deoarece filtrul poate urmări mai multe ipoteze în același timp, nu este recomandat ca toate particulele să fie luate în considerare pentru estimarea benzii. Pentru acest motiv, se aplică un algoritm de clustering, MBSAS, Modified Basic Sequential Algorithm Scheme, descris în [Theodoridis2006]. Mulțimea particulelor este partiționată în  $S$  grupuri (clusters) pe baza distanței dintre particule. Grupul cu cele mai multe particule va genera estimarea drumului:

$$\mathcal{E}(\mathbf{x}_t) = \frac{\sum_{i=R}^N \mathbf{x}_t^i \pi_t^i \delta_t^i}{\sum_{i=R}^N \pi_t^i \delta_t^i} \quad (5.57)$$

Particulele de inițializare complet aleatoare sunt excluse din estimare. Condiția binară  $\delta_t^i$  indică apartenența particulei la grupul maxim:

$$\delta_t^i = \begin{cases} 0, & \text{if } \pi_t^i < \frac{1}{N} \text{ \& } i \in C_{\max} \\ 1, & \text{otherwise} \end{cases} \quad (5.58)$$




Fig. 5.26. Estimarea unui vector de stare din medierea particulelor.

#### *Validarea rezultatului*

Spre deosebire de filtrul Kalman, filtrul de particule nu are nevoie de un proces de inițializare, sau de validarea măsurătorilor înainte de actualizare. Particulele vor evolua liber, grupându-se natural în jurul celor mai puternice măsurători. Totuși, trebuie să știm dacă se urmărește o bandă reală, pentru a putea comunica acest lucru unui sistem de asistență a conducerii. Pentru acest lucru, vom impune două condiții. Prima este ca particulele să fie bine grupate, și pentru asta putem folosi rezultatul algoritmului de clustering. Dacă grupul majoritar conține cel puțin 30% din particule, condiția se consideră împlinită.

Condiția grupării este necesară dar nu și suficientă. Am observat că particulele tind să se grupeze chiar și în prezența unor măsurători slabe. De aceea s-a definit un nou test de validitate, prin compararea ponderii medii a particulelor prezise cu ponderea medie a particulelor aleatoare adăugate. Se definește un factor de calitate:

$$q = \frac{R \sum_{i=R+1}^N \pi_i^i}{(N-R) \sum_{i=1}^R \pi_i^i} \quad (5.59)$$

Dacă  $q$  este mai mare decât un prag, banda este considerată validă. Un factor de calitate mare înseamnă că măsurătorile susțin ipotezele prezise mai mult decât alte ipoteze posibile.

### 5.3.9. Abordarea schimbărilor de bandă

După ce banda curentă a fost detectată și validată, se pot detecta benzile adiacente, dacă acestea există. Se folosește metoda descrisă în capitolul 5.1.

Dacă banda adiacentă se detectează, putem beneficia de acest avantaj la schimbarea benzii. Primul pas este să detectăm momentul schimbării. Pentru aceasta trebuie să monitorizăm traiectoria vehiculului față de bandă, și să anticipăm tranziția. Geometria benzii, combinată cu viteza și viteza angulară, ne permit să calculăm timpul până la ieșirea de pe banda curentă, și vom iniția procesul de comutare a parametrilor când mai sunt aproximativ 5 cadre până la trecerea graniței. Procesul de tranziție consistă în următorii pași:

1) Mutarea densității de probabilitate pe noua bandă. Aceasta înseamnă mutarea tuturor particulelor, cu păstrarea incertitudinilor, pentru a nu da fiecărei particule aceeași valoare.




Fig. 5.27. Înainte de schimbare. Banda laterală este detectată, și se calculează iminența tranziției.




Fig. 5.28. După schimbare. Particulele sunt mutate pe noua bandă, iar numărul de particule de inițializare sunt reduse.

2) Pentru următoarele 30 de cadre, algoritmul de urmărire nu va utiliza particule de inițializare, deoarece aceste particule ar putea să se fixeze pe vechea bandă.

### 5.3.10. Teste și rezultate

#### *Comparația cu filtrul Kalman*

Metoda bazată pe filtrul de particule a fost proiectată pentru a îmbunătăți abordarea situațiilor dificile în care soluțiile descrise în capitolele 5.1 și 5.2 au avut probleme. Deși scenariile cu probleme sunt variate, ele pot fi definite de termenul generic „drum cu discontinuități”. Cele mai frecvente discontinuități sunt: apariția și dispariția benzii, manevre de schimbare a benzii, despicare-unire a benzilor, schimbări abrupte de curbură, sau erori ale senzorului din cauza saturării imaginilor.

Un filtru Kalman are probleme din cauza următoarelor caracteristici:

- Există doar o singură configurație urmărită.
- Starea curentă este folosită pentru prezicerea zonelor de căutare, ceea ce previne considerarea măsurătorilor discontinue.
- Sistemul necesită timp pentru re-inițializare.
- Inițializarea costă timp, din cauza rulării algoritmilor de detecție pe toată imaginea.

Am testat sistemul bazat pe particule în aceste situații, și am constatat următoarele:

1. Apariția și dispariția benzii: datorită faptului că nu există detecție în sensul clasic al cuvântului, nu este nevoie de timp suplimentar pentru a reinițializa sau a șterge o ipoteză. Particulele se vor aduna în jurul unei ipoteze noi și rezultatul va fi validat în 2-3 cadre.

2. La manevrele de schimbare a benzii, există două aspecte ale algoritmului care fac tranziția cât mai ușoară: capacitatea sistemului de a urmări mai multe ipoteze, și folosirea particulelor aleatoare pentru a căuta noi ipoteze. Particulele aleatoare vor iniția un nou grup, iar din cauza mișcării vehiculului spre banda nouă, acest grup va primi tot mai multă importanță, încât noua bandă va fi urmărită înainte de a se termina complet tranziția.

3. Situațiile de despicare sau unire a benzilor sunt tratate în același fel ca schimbarea de bandă. Sistemul este întotdeauna pregătit să preia o ipoteză mai bună dacă aceasta apare.

4. Schimbările bruște de curbură sunt tratate sau prin generarea ipotezelor corecte suficient de repede pentru a prelua noile realități, sau prin revenirea rapidă după ce discontinuitatea a trecut.

5. Deoarece nu există reinițializare, eșecurile senzorului sunt tratate uniform de către sistem. Particulele se vor împrăștia cât timp nu există informație, dar se vor regrupa repede când informația este din nou disponibilă.

O comparare calitativă între metode este prezentată în filmul <http://users.utcluj.ro/~rdanescu/lane/pf-kf.avi>. În partea stângă avem soluția bazată pe particule, iar în dreapta avem rezultatele filtrului Kalman. Câteva cadre sunt prezentate în figura următoare.




Fig. 5.29. Exemple de situații în care a fost făcută comparația. Stânga – filtrul de particule, dreapta – filtrul Kalman.

#### *Evaluarea detecției unghiului de aplecare*

Pentru a se evalua unghiul de aplecare, s-a ales o secvență de imagini cu variație mare a acestui unghi. Deoarece nu putem cunoaște valorile adevărate ale acestui unghi, am ales să comparăm valorile detectate de acest algoritm cu valorile estimate prin interpolarea unor puncte 3D alese dintr-o zonă limitată, din fața vehiculului, unde știm că nu există obstacole. Graficul din figura următoare arată cele două valori, și eroarea dintre ele.




Fig. 5.30. Validarea unghiului de aplecare

#### *Testarea variației curburii*

Parametrul de variație a lățimii extinde aplicabilitatea algoritmului. O situație când lățimea se schimbă constant este intrarea și ieșirea de pe autostradă. Deoarece nu avem valori de referință, vom compara variația estimată cu cea calculată prin folosirea unui model de lățime constantă și calculând variația de la un cadru la altul, normalizată cu distanța parcursă. Rezultatele sunt arătate în filmul <http://users.utcluj.ro/~rdanescu/lane/varwidth.avi>.



Comparația numerică este arătată în graficul din figura de mai jos. Prin folosirea unui model cu curbă variabilă, se obține o curbă mult mai netedă.




Fig. 5.31. Comparația dintre metode de estimare a variației curburii.

### 5.3.11. Concluzii

Acest capitol a prezentat un sistem care folosește avantajele stereoviziunii și ale procesării imaginilor de intensitate, combinate cu avantajele unui algoritm bazat pe filtrul de particule, pentru a urmări benzile de circulație în condiții dificile. Sistemul nu folosește detecție în sensul clasic, nu există inițializare a procesului de urmărire, și nici pierdere a țintei. Se observă o stabilitate excelentă în condiții favorabile, și o capacitate de adaptare rapidă la condiții în schimbare.

Contribuțiile originale ale acestui capitol sunt:

- Metoda de detecție a unghiului de aplecare, o îmbunătățire considerabilă asupra metodei (tot originale) prezentate în capitolul 5.1
- Arhitectura flexibilă pentru soluții bazate pe filtrul de particule
- Metoda de procesare a informațiilor senzoriale
- Procesul de calculare a ponderilor particulelor, care este capabil să facă particulele să se grupeze în jurul benzii corecte folosind un minim de timp de procesare
- Metoda de validare a rezultatului prin folosirea factorului de calitate

Originalitatea realizărilor acestui capitol este confirmată prin publicarea acestora in extenso în lucrarea << R. Danescu, S. Nedeveschi, “Probabilistic Lane Tracking in Difficult Road Scenarios Using Stereovision”, *IEEE Transactions on Intelligent Transportation Systems*, vol. 10, No. 2, June 2009, ISSN 1524-9050, pp. 272-282>>

Jurnalul IEEE-ITS este cel mai prestigios jurnal al domeniului, cu un factor de impact pentru anul 2008 de 2.8, lucrarea noastră fiind publicată in extenso, 11 pagini.

## 5.4. Integrarea sistemului

Acest capitol va prezenta pe scurt integrarea sistemului de urmărire a drumului în sistemul hardware și software SCABOR (Stereo CAmera-Based Object Recognition). SCABOR este un sistem aproape complet de estimare a descrierii mediului înconjurător, pentru aplicații auto, operațional pe mai multe vehicule de testare la fabrica Volkswagen din Wolfsburg. Această aplicație este un cadru de dezvoltare pentru algoritmi noștri începând cu anul 2001.

Algoritmul de urmărire a benzilor primește datele de care are nevoie din două surse: mediul SCABOR oferă punctele 3D pe baza cărora se efectuează detecția, iar magistrala CAN (sistemul intern de comunicație în mașinile Volkswagen) oferă informația despre viteză, unghiul volanului și viteza angulară. Sistemul de urmărire a drumului oferă spre mediul SCABOR parametrii benzilor, pentru integrare cu alți algoritmi și pentru vizualizare, și pentru trimiterea lor pe magistrala CAN pentru integrarea în alte aplicații de asistență a șofatului.

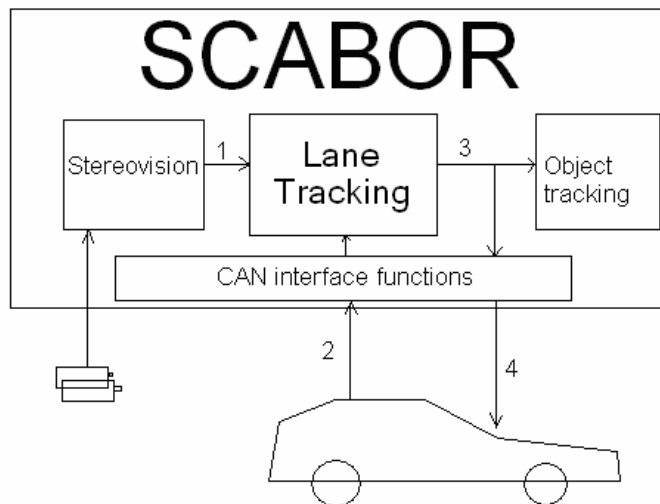


Fig. 5.32. Integrarea sistemului de urmărire a drumului cu alte module

Numerele din figura de mai sus reprezintă:

1. Lista punctelor 3D obținute prin stereoviziune
2. Informația extrasă de pe magistrala CAN
3. Parametrii drumului, rezultatul urmăririi
4. Parametrii drumului codificați pentru magistrala CAN.

## 6. Concluzii

Această teză descrie fundamentele teoretice, starea curentă a cercetării internaționale, tehnicile originale proiectate, sistemele complexe implementate, și rezultatele unei activități de cercetare de șase ani în domeniul urmăririi bazate pe probabilități a drumului.

Prima contribuție originală este un sistem de urmărire a drumului pentru autostradă, care folosește informația 3D furnizată de un algoritm de stereoviziune bazat pe corelarea pe muchii. Această soluție a introdus o tehnică nouă de estimare a profilului vertical, pe baza proiecției laterale a punctelor 3D în spațiul cartezian. Această contribuție a avut un impact asupra tehnicilor de urmărire și detecție a benzii, precum și asupra tehnicilor de detecție a obstacolelor, deoarece s-a putut efectua o separare precisă a punctelor de drum de punctele de obstacol. Mai mult, prin estimarea directă a parametrilor profilului vertical, gradele de libertate pentru potrivirea probabilistică a modelului sunt mult reduse, permițând o robustețe crescută a rezultatelor. Cele mai populare presupuneri care au caracterizat sistemele existente în literatură, precum drumul plat, unghiul de aplecare constant, absența unghiului de înclinare, au putut fi eliminate. Sistemul de urmărire a benzilor de autostradă aduce și alte realizări originale: dezvoltarea unui algoritm original de corespondență între spațiul 3D și cel al imaginii, care ia în considerare geometria generală a camerelor și modelul general al drumului, dezvoltarea unei metode originale de estimare a benzilor adiacente pe baza punctelor 3D, și alte validări care asigură corectitudinea rezultatelor.

Realizările și experiența obținute prin dezvoltarea sistemului de urmărire a benzilor dedicat traficului pe autostradă au permis abordarea unei probleme mai dificile și mai complexe, urmărirea benzilor în mediul urban. Am dezvoltat un sistem care a trebuit să depășească greutățile puse de o vizibilitate redusă a șoselei, de un câmp vizual adesea ocupat de obstacole, de prezența unor trăsături pe șosea care puteau fi delimitatoare dar puteau fi și elemente non-delimitante, și de prezența unor geometrii care uneori nu respectă modelul. Pentru a obține rezultate robuste în aceste scenarii adverse, a trebuit să proiectez un algoritm original de extragere a marcajelor rutiere, care se bazează pe modelul tradițional de detecție a tranzițiilor întuneric-lumină-întuneric, dar realizează această detecție pe baza unui filtru de diferențiere de lățime variabilă, adaptat efectului de perspectivă, și apoi face căutarea perechilor de muchii folosind zone de căutare care țin cont de același efect de perspectivă. Lățimea nucleului de derivare, și a zonelor de căutare pentru stabilirea perechilor de muchii se face folosind parametrii camerei, obținuți prin calibrarea sistemului de stereoviziune.

Pe lângă detectarea trăsăturilor de tip marcaj rutier în spațiul imagine, sistemul de urmărire folosește profilul vertical detectat prin metoda dezvoltată pentru aplicațiile de autostradă, și selecția punctelor de șosea pe baza acestui profil, obținând un detector de marcaje care beneficiază și de avantajele stereoviziunii, și de avantajele procesării imaginilor de intensitate. După detecția trăsăturilor, sistemul se bazează pe multiple detecții de primitive intermediare, linii și curbe, extrase cu algoritmi care sunt îmbunătățiri originale ale unor tehnici existente. Aceste rezultate intermediare sunt fuzionate printr-un sistem original, bazat pe probabilități, care este capabil să integreze informații eterogene pentru estimarea parametrilor unui model unic.

Sistemele de urmărire a benzilor pentru autostradă și pentru mediul urban au fost dezvoltate folosind schema generică de urmărire Kalman. Filtrul Kalman este o soluție foarte robustă pentru un sistem de urmărire, care asigură rezultate stabile și timpi de reacție rapizi, datorită capacității de netezire a rezultatelor și a capacității de a reduce spațiul de căutare folosind

predicția. Totuși, multe situații de trafic implică discontinuități în parametrii drumului. Aceste situații includ intersecțiile, ieșirile și intrările autostrăzilor, despărțirea benzilor, etc. Pentru a îmbunătăți urmărirea benzilor în aceste situații, am dezvoltat o soluție bazată pe un filtru de particule, capabilă de a acoperi și situațiile urbane și cele de autostradă.

O soluție care utilizează filtrul bazat pe particule nu folosește detecția în sensul clasic al cuvântului, nu există inițializare nici oprire a procesului de urmărire, și astfel timpul de procesare este constant indiferent de scenariu. Pe lângă utilizarea unei alte metode generale de urmărire, soluția aceasta aduce alte contribuții originale. O astfel de îmbunătățire este metoda de detecție a unghiului de aplecare, o îmbunătățire substanțială a primei metode, care este și ea originală, și care îmbunătățește rezultatul estimării unghiului de aplecare, și prin aceasta și selecția punctelor de șosea. Soluția bazată pe filtrul de particule a fost realizată folosind o arhitectură software originală și flexibilă, care poate fi extinsă la multiple soluții de urmărire, cum ar fi urmărirea obstacolelor. Alegerea informațiilor care vor fi folosite pentru procesul de măsurătoare, algoritmi folosiți pentru extragerea acestor informații, modul în care particulele sunt comparate cu măsurătorile, și metodele pentru validarea rezultatelor, sunt tot atâtea contribuții originale ale noii metode de urmărire.

Prezentăm aici o trecere în revistă a principalelor **contribuții** ale acestei teze:

1. Un studiu al literaturii de specialitate din domeniul urmăririi drumului, și a literaturii din domeniile asociate, a dus la:

- O descriere detaliată a problemei urmăririi ca raționare bazată pe probabilități.
- O prezentare detaliată a filtrului Kalman și a variantelor acestuia, filtrul Kalman extins și filtrul Kalman Unscented, într-o manieră care combină aspectele teoretice cu soluțiile la problemele ingineresti care pot fi întâlnite la proiectarea unui sistem de urmărire.
- O prezentare detaliată a filtrului bazat pe particule și a variantelor acestuia, cu explicarea mecanismelor teoretice, a considerentelor de implementare, și a variantelor de inițializare și estimare.
- O trecere în revistă a modelelor drumului folosite de cercetătorii renumiți din domeniu. Pentru acest material s-au scris demonstrații originale pentru derivarea modelelor statice și dinamice. Cititorul poate compara modele multiple, adaptate pentru diferite probleme.
- O trecere în revistă a principalelor tehnici de extragere a trăsăturilor delimitatoare ale benzilor, ce compară metode de procesare a imaginilor de intensitate, imagini color și imagini stereo, sau tehnici de procesare a datelor oferite de senzorii active.
- O trecere în revistă a tehnicilor de potrivire a modelului, unele bazate pe probabilități, care sunt dedicate potrivirii modelelor drumului la datele trăsături. În acest capitol, unele metode sunt prezentate în detaliu, și unele demonstrații originale sunt adăugate materialului găsit în literatură.

Prin aceste studii, prima parte a tezei este un material valoros care construiește baza științifică pentru dezvoltările originale următoare, și care poate constitui un posibil manual pentru cercetătorii potențiali din domeniu.

2. Proiectarea și dezvoltarea unui sistem original pentru urmărirea benzilor pe autostradă și pe drumuri rurale, folosind paradigma filtrului Kalman și senzorul de stereoviziune, ce include:

- Folosirea celui mai general model static și dinamic disponibil, fără presupunerile care erau comune soluțiilor existente.
- Folosirea datelor despre dinamica autovehiculului (date odometrice) pentru predicția stării drumului. Sistemele care monitorizează dinamica autovehiculului, disponibile în autovehiculele moderne, precum ABS și ESP, au pus la dispoziție informații despre viteză,

viteza angulară, și unghiul volanului, prin magistrala CAN, iar aceste date au fost integrate în procesul de predicție.

- Soluția originală de integrare a unui algoritm de detecție a orizontului în predicția variației unghiului de aplecare.
- Algoritm original pentru proiecția parametrilor din spațiul stărilor în spațiul imagine, care elimină majoritatea presupunerilor folosite în mod tradițional.
- Metoda originală de detecție a profilului vertical, bazată pe histograme, care utilizează pentru prima dată informația stereo sub forma punctelor 3D, în locul disparităților, și care include și curbura verticală a drumului.
- Separația dintre trăsăturile șoselei și trăsăturile obstacolelor, folosind profilul vertical detectat.
- Metoda originală de potrivire a segmentelor multiple în zonele de căutare, pe baza clasei punctelor incluse, ca parte a procesului de potrivire a modelului drumului în spațiul imagine.
- Metoda originală de extragere a parametrilor 3D din rezultatul potrivirii modelului în spațiul imagine.
- Metoda originală, bazată pe stereoviziune, de detecție a unghiului de înclinare.
- Metoda originală de detecție a benzilor laterale, bazată pe stereoviziune și pe presupunerea că toate benzile drumului au aceeași orientare.
- Metodele originale de validare a inițializării procesului de urmărire a drumului.

3. Proiectarea și dezvoltarea unui sistem original de urmărire a benzilor pentru mediul urban, folosind paradigma filtrului Kalman și stereoviziunea, ce include:

- O metodă originală de modelare a drumului urban, combinând modelul clotoidal cu un model cu formă liberă pentru margini nonstandard.
- O arhitectură originală pentru sistemul de urmărire, care este capabilă să fuzioneze multiple indicii eterogene pentru a actualiza un singur model unificat. Arhitectura este bazată pe filtrul Kalman extins, dar folosește mai multe modele de măsură pentru multiple surse de informație. Trăsătura definitorie a acestui sistem este posibilitatea de a utiliza măsurători simple pentru actualizarea unui model complex.
- Soluția originală pentru extragerea marcajelor de drum, ce folosește un filtru adaptat cu efectul de perspectivă pentru a calcula derivate orizontale a imaginii, pentru a găsi modelul de tranziție întuneric-lumină-întuneric specific marcajelor. Parametrii camerei sunt folosiți pentru a estima corect efectul de perspectivă, și informația stereo 3D este folosită pentru a valida marcajele posibile extrase din imagine.
- Metoda originală pentru potrivirea segmentelor de dreaptă la trăsăturile delimitatoare, metodă ce se bazează pe o metodă originală, eficientă computațional, pentru reprezentarea parametrică a dreptei, și folosește constrângeri geometrice pentru a limita spațiul de căutare și pentru a selecta doar acele drepte care pot forma marginile unei benzi. O altă trăsătură inovatoare a algoritmului este folosirea ponderilor trăsăturilor, derivate din tipul acestora.
- Metoda originală de abordare a potrivirii modelului în două zone de distanță, ce asigură că detecția poate fi reușită și la o distanță de vizibilitate foarte mică, dar care permite o rafinare a rezultatelor dacă drumul devine vizibil pe o distanță mai lungă.
- Metoda originală de detecție a marginilor drumului fără constrângerile unui model, ce se bazează pe marcajele din spațiul 3D și potrivirea unor curbe de tip spline la aceste trăsături.

4. Proiectarea și implementarea unui sistem original de urmărire a benzilor pentru scenarii dificile, urbane și non-urbane, bazat pe stereoviziune și pe filtrul de particule, ce include:

- Un model original pentru urmărirea benzilor, ce extinde cele mai complexe modele disponibile în literatură. Acest model include un deplasament vertical, adăugat profilului vertical existent, lățimea marcajelor stâng și drept, și variația lățimii benzii cu distanța.

- O arhitectură software originală ce implementează mecanismul de filtrare bazat pe particule într-o manieră polimorfică ce poate fi extinsă la orice problemă de urmărire, cu modificări minime.
- Metoda originală de detecție a unghiului de aplecare, ce extinde primele noastre contribuții originale din domeniu, îmbunătățind considerabil rezultatele.
- Selecția originală de indicii folosită pentru procesul de măsură: metoda originală de extragere a maximelor de densitate a punctelor 3D pentru urmărirea profilului vertical, combinația originală de muchii, borduri și marcaje pentru mulțimea de trăsături din spațiul imagine, și folosirea gradientului calculate cu filtrul de dimensiune variabilă ca trăsătură primară pentru estimarea lățimii marcajelor.
- Metodele originale de comparare a particulelor cu datele de măsură, ce folosesc un număr mic de puncte și calcule simple, ceea ce permite sistemului o viteză mare de execuție chiar și când se folosește un număr mare de particule.
- Metoda originală de validare a rezultatului urmăririi, bazată pe un factor de calitate original ce monitorizează distribuția particulelor re-eșantionate față de datele de măsură și față de particulele aleatoare de inițializare.
- Metoda originală de abordare a schimbărilor de bandă prin monitorizarea traiectoriei vehiculului și a anticipării momentului de tranziție, urmată de transferul întregii mulțimi de particule pe noua bandă.

Cercetarea și rezultatele prezentate în această teză sunt bine integrate în activitatea științifică internațională. Baza cercetării noastre a fost formată de ultimele realizări din domeniu; rezultatele sunt publicate în 28 de articole științifice, din care unul într-o revistă cotate ISI și 16 în volume ISI Proceedings. Relevanța acestor lucrări este demonstrată de citarea lor de către cercetători importanți, iar acest lucru înseamnă că rezultatele muncii prezentate în această teză contribuie activ la dezvoltarea cunoașterii științifice și ingineresti din domeniu.

## Bibliografie

[**Aufrere2000**] - R. Aufrere, R. Chapuis, F. Chausse, "A fast and robust vision-based road following algorithm", in proc of *IEEE-Intelligent Vehicles Symposium 2000 (IEEE-IV 2000)*, pp. 192-197.

[**Aufrere2001**] – R. Aufrere, R. Chapuis, F. Chausse, "A model-driven approach for real-time road recognition", *Machine Vision and Applications, Springer-Verlag*, Vol. 13, No. 2, November 2001, pp. 95-107

[**Aufrere2004**] – R. Aufrere, V. Marion, J. Laneurit, C. Lewandowski, J. Morillon, R. Chapuis, "Road sides recognition in non-structured environments by vision", in proc of *IEEE-Intelligent Vehicles Symposium 2004 (IEEE-IV 2004)*, pp. 329-334.

[**Bar-Shalom1988**] Y. Bar-Shalom, T.E. Fortmann, "Tracking and Data Association", Academic Press Inc., 1988

[**Bertozi1998**] – M. Bertozi, A. Broggi, "GOLD: A Parallel Real-Time Stereo Vision System for Generic Obstacle and Lane Detection", *IEEE Transactions on Image Processing*, Vol. 7, Issue 1, January, 1998, pp. 62-81.

[**Bertozi1998A**] – M. Bertozi, A. Broggi, A. Fascioli, "An Extension to the Inverse Perspective Mapping to handle non-flat roads", in proc of *IEEE-Intelligent Vehicles Symposium 1998, (IEEE-IV 1998)*, pp. 305-310.

[**Bertozi2002**] – M. Bertozi et al., "An Evolutionary Approach to Lane Markings Detection in Road Environments", in proc of *Atti del 6 Convegno dell'Associazione Italiana per l'Intelligenza Artificiale*, September 2002, pp. 627-636

[**Bock1998**] R. K. Bock, "Sampling from a Probability Density Function", online resource at CERN, <http://rkb.home.cern.ch/rkb/AN16pp/node252.html>

[**Bouguet**] J.Y. Bouguet, Camera Calibration Toolbox for Matlab, online resource at CalTech, [http://www.vision.caltech.edu/bouguetj/calib\\_doc/](http://www.vision.caltech.edu/bouguetj/calib_doc/).

[**Broggi1995**] – A. Broggi, "Robust Real-Time Lane and Road Detection in Critical Shadow Conditions", in proc of *IEEE International Symposium on Computer Vision, 1995*, pp.353-358.

[**Campbell1996**] – N. W. Campbell, B. T. Thomas, "Segmentation of Natural Images using Self-Organizing Feature Maps", in proc of *British Machine Vision Conference (BMVC), 1996*, pp. 223-232.

[**Catmull1974**] – E. Catmull, R. Rom, "A Class of Local Interpolating Splines", in *Computer Aided Geometric Design*, Academic Press, 1974, ISBN 0120790505

[**Carsense2007**] –Proiectul european CARSENSE, <http://www.carsense.org/en/index.php>.

**[Chan2007]** Y. M. Chan, S. S. Huang, L. C. Fu, P. Y. Hsiao, “Vehicle Detection under Various Lighting Conditions by Incorporating Particle Filter”, in proc of *IEEE Intelligent Transportation Systems Conference 2007 (ITSC 2007)*, pp. 534-539.

**[Chapuis1999]** - R. Chapuis, R. Aufrere, F. Chausse, “Recovering the 3D shape of a road by vision”, in proc of *IEEE Seventh International Conference on Image Processing and its Applications, 1999*, pp. 686-690.

**[Chapuis2000]** – R. Chapuis, F. Marmoiton, R. Aufrere, “Road Detection and Vehicle Tracking by Vision for an On-Board ACC System in the VELAC vehicle”, in proc of *Third International Conference on Information Fusion, 2000*, pp. WEB5/11- WEB5/18.

**[Chausse2000]** - F. Chausse, R. Aufrere, R. Chapuis, “Vision based vehicle trajectory supervision”, in proc of *IEEE Intelligent Transportation Systems 2000, (IEEE-ITS 2000)*, pp. 143-148.

**[Chech2004]** – M. Chech. W. Niem, S. Abraham, C. Stiller, “Dynamic Ego-Pose Estimation for Driver Assistance in Urban Environments“, in proc of *IEEE Intelligent Vehicles Symposium 2004 (IEEE-IV 2004)*, pp. 43- 48.

**[Chern2004]** – M. Y. Chern, “Knowledge-based Region Classification for Locating Rural Road Area in the Color Scene Image”, in proc of *IEEE International Conference on Networking, Sensing and Control (ICNSC) 2004*, pp. 891-896.

**[Corridori2004]** – C. Corridori, M. Zanin – “High Curvature Two-Clothoid Road Model Estimation”, in proc of *IEEE Intelligent Transportation Systems Conference 2004 (IEEE-ITSC 2004)*, pp. 630- 635.

**[Cramer2004]** – H. Cramer, U. Scheunert, G. Wanielik, “A New Approach for Tracking Lanes by Fusing Image Measurements with Map Data”, in proc of *IEEE Intelligent Vehicles Symposium 2004 (IEEE-IV 2004)*, pp. 607- 612.

**[Crisman1991]** - J.D. Crisman, C. E. Thorpe, “UNSCARF, A Color Vision System for the Detection of Unstructured Roads”, in proc of *IEEE International Conference on Robotics and Automation 1991 (ICRA 1991)*, pp. 2496-2501, vol.3.

**[Danescu2006a]** – R. Danescu, S. Nedevschi, “Robust Real-Time Lane Delimiting Features Extraction” , in proc of *IEEE 2-nd International Conference on Intelligent Computer Communication and Processing 2006 (IEEE-ICCP 2006)*, pp. 77-82.

**[Danescu2006b]** – R. Danescu, S. Sobol, S. Nedevschi, T. Graf, “Stereovision-Based Side Lane and Guardrail Detection”, in proc of *IEEE Intelligent Transportation Systems Conference 2006 (ITSC 2006)*, pp. 1156-1161.

**[Danescu2007a]** – R. Danescu, S. Nedevschi, M.M. Meinecke, T. Graf, “Stereovision Based Vehicle Tracking in Urban Traffic Environments”, in proc of *IEEE Intelligent Transportation Systems Conference 2007 (ITSC 2007)*, pp. 400-404.



**[Danescu2007b]** – R. Danescu, S. Nedevschi, M.M. Meinecke, T.B. To, “Lane Geometry Estimation in Urban Environments Using a Stereovision System”, in proc of *IEEE Intelligent Transportation Systems Conference 2007 (ITSC 2007)*, pp. 271-276.

**[Danescu2007c]** – R. Danescu, S. Nedevschi, T. B. To, “A Stereovision-Based Lane Detector for Marked and Non-Marked Urban Roads”, in proc of *IEEE 3-rd International Conference on Intelligent Computer Communication and Processing 2007 (IEEE-ICCP 2007)*, pp. 81-88.

**[Danescu2008a]** – R. Danescu, S. Nedevschi, “Adaptive and Robust Road Tracking System Based on Stereovision and Particle Filtering”, in proc. of *IEEE International Conference on Intelligent Computer Communication and Processing 2008 (ICCP 2008)*, pp. 67-73.

**[Danescu2008b]** – R. Danescu, S. Nedevschi, M. M. Meinecke, T. B. To, “A Stereovision-Based Probabilistic Lane Tracker for Difficult Road Scenarios”, in proc of *IEEE Intelligent Vehicles Symposium 2008 (IV2008)*, pp. 536-541.

**[Danescu2009c]** – R. Danescu, D. Lebu, F. Oniga, S. Nedevschi, M.-M. Meinecke, “A Flexible Solution for Detection and Tracking of Multiple Objects”, in proc of *IEEE International Conference on Intelligent Computer Communication and Processing 2009 (ICCP 2009)*, pp. 165-168

**[Danescu2009d]** – R. Danescu, F. Oniga, S. Nedevschi, M-M. Meinecke, “Tracking Multiple Objects Using Particle Filters and Digital Elevation Maps”, in proc of *IEEE Intelligent Vehicle Symposium 2009 (IEEE-IV 2009)*, pp. 88-93.

**[Danescu2009e]** – R. Danescu, S. Nedevschi, “Probabilistic Lane Tracking in Difficult Road Scenarios Using Stereovision”, *IEEE Transactions on Intelligent Transportation Systems*, vol. 10, No. 2, June 2009, ISSN 1524-9050, pp. 272-282.

**[Dickmanns1986]** - E.D. Dickmanns, A. Zapp, “A Curvature-Based Scheme for Improving Road Vehicle Guidance by Computer Vision”, in proc *SPIE Conference on Mobile Robots*, vol. 727, 1986, pp. 161-168.

**[Dickmanns1992]** - 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, pp. 199-213, 1992.

**[Fardi2003]** – B. Fardi, U. Scheunert, H. Cramer, G. Wanielik, “Multi-Modal Detection and Parameter-based Tracking of Road Borders with a Laser Scanner”, in proc of *IEEE Intelligent Vehicles Symposium 2003 (IEEE-IV 2003)*, pp. 95- 99.

**[Forsyth2003]** – D. Forsyth, J. Ponce, “Computer Vision – A Modern Approach”, *Prentice Hall*, 2003.

**[Franke1999]** – U. Franke, D. Gavrila, S. Goerzig, F. Lindner, F. Paetzold, C. Woehler, “Autonomous Driving approaches Downtown”, *IEEE Intelligent Systems*, vol. 13, nr. 6, 1999, pp. 40-48.

- [**Franke2007**] U. Franke, H. Loose, C. Knoepfel, „Lane Recognition on Country Roads“, in proc of *IEEE Intelligent Vehicles Symposium 2007 (IEEE-IV 07)*, pp. 99-104.
- [**Gern2000**] – A. Gern, U. Franke, P. Levi, “Advanced lane recognition-fusing vision and radar”, in proc of *IEEE Intelligent Vehicles Symposium 2000 (IEEE-IV 2000)*, pp. 45-51.
- [**Goldbeck1998**] – J. Goldbeck, G. Draeger, B. Huertgen, S. Ernst, F. Wilms, “Lane Following Combining Vision and DGPS”, in proc of *IEEE Intelligent Vehicles Symposium 1998 (IEEE-IV 1998)*, pp. 425-433.
- [**Goldbeck1999**] – J. Goldbeck, B. Huertgen, “Lane Detection and Tracking by Video Sensors”, in proc of *IEEE International Conference on Intelligent Transportation Systems 1999 (IEEE-ITSC 1999)*, pp. 74–79.
- [**Gonzalez2000**] – J.P. Gonzalez, U. Ozguner, “Lane Detection Using Histogram-Based Segmentation and Decision Trees”, in proc of *IEEE Intelligent Transportation Systems 2000 (IEEE-ITS 2000)*, pp. 346–351.
- [**Isard1998**] M. Isard, A. Blake, “CONDENSATION - conditional density propagation for visual tracking”, *International Journal of Computer Vision*, vol. 29, no. 1, 1998, pp. 5-28.
- [**Julier1997**] S. J. Julier, J. K. Uhlmann, "A new extension of the Kalman filter to nonlinear systems", *International Symposium of Aerospace/Defense Sensing, Simulation and Controls*, 1997.
- [**Jung2004**] – C.R. Jung, C.R. Kelber, “A Lane Departure Warning System based on a Linear-Parabolic Lane Model”, in proc of *IEEE Intelligent Vehicles Symposium 2004 (IEEE-IV 2004)*, pp. 891- 895.
- [**Kalman1960**] 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.
- [**Kang1996**] – D.J. Kang, J. W. Choi, I. S. Kweon, ”Finding and Tracking Road Lanes Using <<Line Snakes>>”, in proc of *IEEE Intelligent Vehicles Symposium 1996 (IEEE-IV 1996)*, pp. 189-194.
- [**Kim2006**] – Z. Kim, “Realtime Lane Tracking of Curved Local Road”, in proc of *IEEE Intelligent Transportation Systems Conference 2006 (IEEE-ITSC 2006)*, pp. 1149-1155.
- [**Kirchner1998**] – A. Kirchner, T. Heinrich, “Model based detection of road boundaries with a laser scanner”, in proc of *IEEE Intelligent Vehicles Symposium 1998 (IEEE-IV 1998)*, pp. 93-98.
- [**Kluge1995**] – K. Kluge, S. Lankshmanan, “A Deformable-Template Approach to Lane Detection”, in proc of *IEEE Intelligent Vehicles Symposium 1995 (IEEE-IV 1995)*, pp. 54-59.
- [**Kreucher1998**] – C. Kreucher, S. Lanksmanan, K. Kluge, “A Driver Warning System Based on the LOIS Lane Detection Algorithm”, in proc of *IEEE Intelligent Vehicles Symposium 1998 (IEEE-IV 1998)*, pp. 17-22.

**[Kreucher1999]** – C. Kreucher, S. Lankshmanan, “LANA: A Lane Extraction Algorithm that Uses Frequency Domain Features”, *IEEE Transactions on Robotics and Automation*, Vol. 15, No. 2, 1999, pp. 343-350.

**[Labayrade2003]** – R. Labayrade, D. Aubert, “A single framework for Vehicle Roll, Pitch, Yaw Estimation and Obstacles Detection by Stereovision”, in proc of *IEEE Intelligent Vehicles Symposium 2003 (IEEE-IV 2003)*, pp. 31-36.

**[Labayrade2004]** – R. Labayrade, S. S. Ieng, D. Aubert, “A Reliable Road Lane Detector Approach Combining Two Vision-Based Algorithms”, in proc of *IEEE Intelligent Transportation Systems Conference 2004 (IEEE-ITSC 2004)*, pp. 149-154.

**[Ma1999]** – B. Ma, S. Lankshmanan, A. Hero, “Road and Lane Edge Detection with Multisensor Fusion Methods”, in proc of *International Conference on Image Processing 1999 (ICIP 1999)*, pp. 686-690.

**[MacCormick1999]** J. MacCormick, A. Blake, “A Probabilistic Exclusion Principle for Tracking Multiple Objects”, *International Journal of Computer Vision*, vol. 39, No 1, 2000, pp. 57-71.

**[Macek2004]** K. Macek, B. Williams, S. Kolski, R. Siegwart, “A Lane Detection Vision Module for Driver Assistance”, in proc of *IEEE/APS Conference on Mechatronics and Robotics*, 2004, pp. 77-82.

**[Marita2006]** T. Marita, F. Oniga, S. Nedevschi, T. Graf, R. Schmidt, “Camera Calibration Method for Far Range Stereovision Sensors Used in Vehicles”, in proc of *IEEE Intelligent Vehicles Symposium 2006 (IV 2006)*, pp. 356-363.

**[Marita07]** – T. Marița, F. Oniga, S. Nedevschi, T. Graf, “Calibration Accuracy Assessment Methods for Stereovision Sensors Used in Vehicles”, in proc of *IEEE 3-rd International Conference on Intelligent Computer Communication and Processing 2007 (ICCP 2007)*, pp. 111-118.

**[McCall2004]** – J. C. McCall, M. M. Trivedi, “An Integrated, Robust Approach to Lane Marking Detection and Lane Tracking”, in proc of *IEEE Intelligent Vehicles Symposium 2004 (IEEE-IV 2004)*, pp. 533- 537.

**[Meier1999]** E. B. Meier, F. Ade, “Using the Condensation Algorithm to Implement Tracking for Mobile Robots”, in proc of *The Third European Workshop on Advanced Mobile Robots, Eurobot99*, 1999, pp. 73-80.

**[Meis2003]** – U. Meis, R. Schneider, “Radar image acquisition and interpretation for automotive applications”, in proc of *IEEE Intelligent Vehicles Symposium 2003 (IEEE-IV 2003)*, pp. 328-332.

**[Nedevschi2002]** – S. Nedevschi, T. Marita, M. Vaida, R. Danescu, D. Frentiu, F. Oniga, C. Pocol, “Camera Calibration Method for Stereo Measurements”, *Journal of Control Engineering and Applied Informatics (CEAI)*, Vol. 4, No. 2, 2002, pp. 21-28.

**[Nedevschi2004a]** – S. Nedevschi, R. Danescu, D. Frentiu, T. Marita, F. Oniga, C. Pocol, R. Schmidt, T. Graf, “Stereovision Approach For Obstacle Detection On Non-Planar Roads”, in proc of *1st International Conference on Informatics in Control, Automation and Robotics (ICINCO)*, 2004, Vol. 2, pp. 11-18.

**[Nedevschi2004b]** – S. Nedevschi, R. Danescu, D. Frentiu, T. Marita, F. Oniga, C. Pocol , “Spatial Grouping of 3D Points from Multiple Stereovision Sensors”, in proc of *IEEE International Conference on Networking, Sensing and Control (ICNSC) 2004*, pp. 874-879.

**[Nedevschi2004c]** – S. Nedevschi, R. Danescu, D. Frentiu, T. Marita, F. Oniga, C. Pocol, Thorsten Graf, Rolf Schmidt, “High Accuracy Stereovision Approach for Obstacle Detection on Non-Planar Roads”, *IEEE Intelligent Engineering Systems 2004 (IEEE-INES 2004)*, pp. 211-216.

**[Nedevschi2004d]** – S. Nedevschi, R. Schmidt, T. Graf, R. Danescu, D. Frentiu, T. Marita, F. Oniga, C. Pocol, “3D Lane Detection System Based on Stereovision”, in proc of *IEEE Intelligent Transportation Systems Conference 2004 (IEEE-ITSC 2004)*, pp. 161-166.

**[Nedevschi2004e]** – S. Nedevschi, R. Schmidt, T. Graf, R. Danescu, D. Frentiu, T. Marita, F. Oniga, C. Pocol, “High Accuracy Stereo Vision System for Far Distance Obstacle Detection”, in proc of *IEEE Intelligent Vehicles Symposium 2004 (IEEE-IV 2004)*, pp.161-166.

**[Nedevschi2005a]** - S. Nedevschi, R. Danescu, T. Marita, F. Oniga, C. Pocol, “Moving Camera Rotation Estimation Using Horizon Line Features’ Motion Field”, in proc of *6-th International Carpathian Control Conference*, 2005, Lilafured-Miskolc, Hungary, pp.449-454, ISBN 963-661-645-0.

**[Nedevschi2005b]** – S. Nedevschi, R. Danescu, T. Marita, F. Oniga, C. Pocol, S. Sobol, T. Graf, R. Schmidt, “Driving Environment Perception Using Stereovision”, in proc of *IEEE Intelligent Vehicles Symposium 2005 (IEEE-IV2005)*, pp.331-336.

**[Nedevschi2006a]** – S. Nedevschi, T. Marita, R. Danescu, F. Oniga, C. Pocol, S. Sobol, C. Tomiuc, C. Vancea, S. Bota, “Stereovision Sensor for Driving Assistance”, in proc of *IEEE 2-nd International Conference on Intelligent Computer Communication and Processing 2006 (IEEE-ICCP 2006)*, pp. 105-111.

**[Nedevschi2006b]** – S. Nedevschi, F. Oniga, R. Danescu, T. Graf, R. Schmidt, “Increased Accuracy Stereo Approach for 3D Lane Detection”, in proc of *IEEE Intelligent Vehicles Symposium 2006 (IEEE-IV 2006)*, pp. 42-49.

**[Nedevschi2007a]** – S. Nedevschi, R. Danescu, T. Marita, F. Oniga, C. Pocol, S. Sobol, C. Tomiuc, C. Vancea, M.M. Meinecke, T. Graf, T. B. To, M.A. Obojski, “A Sensor for Urban Driving Assistance Systems Based on Dense Stereovision”, in proc of *IEEE Intelligent Vehicles Symposium 2007 (IEEE-IV 2007)*, pp. 276-283.

**[Nedevschi2007b]** – S. Nedevschi, C. Vancea, T. Marita, T. Graf, “On-Line Calibration Method for Stereovision Systems Used in Far Range Detection Vehicle Applications”, *IEEE Transactions on Intelligent Transportation Systems*, vol. 8, no. 4, pp. 651-660, December, 2007.

**[Nedevschi2008a]** – S. Nedevschi, R. Danescu, C. Pocol, M. M. Meinecke, “Stereo Image Processing for ADAS and Pre-Crash Systems”, in proc of *5th International Workshop on Intelligent Transportation 2008 (WIT 2008)*, Hamburg; pp. 55-60.

**[Nedevschi2008b]** – S. Nedevschi, R. Danescu, T. Marita, F. Oniga, C. Pocol, S. Bota and C. Vancea, “A Sensor for Urban Driving Assistance Systems Based on Dense Stereovision”, book chapter in “*Stereo Vision*” editor A. Bhatti, published by *InTech Education and Publishing*, Vienna, November 2008, ISBN 978-953-7619-22-0, pp. 235-258.

**[Nedevschi2009a]** – S. Nedevschi, R. Danescu, T. Marita, F. Oniga, C. Pocol, S. Bota, M-M. Meinecke, M. A. Obojski, “Stereovision-Based Sensor for Intersection Assistance”, book chapter in *Advanced Microsystems for Automotive Applications, April 2009, Springer*, ISBN 978-3-642-00744-6, pp. 129-163.

**[Nedevschi2009b]** – S. Nedevschi, T. Marita, R. Danescu, F. Oniga, S. Bota, “On-board Stereo Sensor for Intersection Driving Assistance. Architecture and Specification”, in proc of *IEEE International Conference on Intelligent Computer Communication and Processing 2009 (ICCP 2009)*, pp. 409-416.

**[Oniga2006]** S. Nedevschi, F. Oniga, R. Danescu, T. Graf, R. Schmidt, “Increased Accuracy Stereo Approach for 3D Lane Detection”, in proc of *IEEE Intelligent Vehicles Symposium 2006, (IEEE-IV 2006)*, pp. 42-49.

**[Oniga2007]** – F. Oniga, S. Nedevschi, M.M. Meinecke, T.B. To, “Road Surface and Obstacle Detection Based on Elevation Maps from Dense Stereo”, in proc of *IEEE Intelligent Transportation Systems Conference 2007 (ITSC 2007)*, pp. 859-865.

**[Oniga2009]** – F. Oniga, S. Nedevschi, R. Danescu, M.-M. Meinecke, “Global Map Building Based on Occupancy Grids Detected from Dense Stereo in Urban Environments”, in proc of *IEEE International Conference on Intelligent Computer Communication and Processing 2009 (IEEE-ICCP 2009)*, pp. 111-117.

**[Park2000]** – S. T. Park, S. Y. Yang, J. H. Jung, “Real-Time Lane Recognition by Simulated Annealing Algorithm”, in proc of *4th Korea-Russia Symposium on Science and Technology 2000 (KORUS 2000)*, Vol. 3, pp. 95-98.

**[Rasmussen2002]** – C. Rasmussen, “Combining Laser Range, Color, and Texture Cues for Autonomous Road Following”, in proc of *IEEE Conference on Robotics and Automation 2002 (IEEE-ICRA 2002)*, vol. 4, pp. 4320-4325.

**[Risack1998]** – R. Risack, P. Klausmann, W. Kruger, W. Enkelmann, “Robust Lane Recognition Embedded in a Real-Time Driver Assistance System”, in proc of *IEEE Intelligent Vehicles Symposium 1998 (IEEE-IV 1998)*, pp. 35-40.

**[Rotaru2004]** – C. Rotaru, T. Graf, J. Zhang, “Extracting Road Features from Color Images using a Cognitive Approach”, in proc of *IEEE Intelligent Vehicles Symposium 2004 (IEEE-IV 2004)*, pp. 298-303.

[**Sakurai1998**] – K. Sakurai, S. Kyo, S. Okazaki, “A Lane Recognition Method Based on White Line Detection and Road Area Detection”, in proc of *IEEE Intelligent Vehicles Symposium 1998 (IEEE-IV 1998)*, pp. 58-62.

[**Smuda2006**] – P. Smuda, R. Schweiger, H. Neumann, W. Ritter, “Multiple Cue Data Fusion with Particle Filters for Road Course Detection in Vision Systems“, in proc of *IEEE Intelligent Vehicles Symposium 2006 (IEEE-IV 2006)*, pp. 400-405.

[**Sobol2006**] – S. Sobol, S. Nedevschi, “Driving area detection”, in proc of *IEEE 2-nd International Conference on Intelligent Computer Communication and Processing 2006 (IEEE-ICCP 2006)*, poster volume, pp. 89-94.

[**Sorensen1985**] H. W. Sorensen, editor, “Kalman filtering: theory and application”, *IEEE Press*, 1985.

[**Sotelo2004**] – M. A. Sotelo, F. J. Rodriguez, L. Magdalena, L. M. Bergasa, L. Buquete, “A Color Vision-Based Lane Tracking System for Autonomous Driving on Unmarked Roads”, *Autonomous Robots, Kluwer Academic Publishers*, Vol. 16, No. 1, 2004, pp. 95-116.

[**Southall2001**] - J.B. Southall, C.J. Taylor "Stochastic road shape estimation", in proc of *International Conference on Computer Vision*, 2001, pp. 205-212.

[**Taylor1996**] – C. Taylor, J. Malik, J. Weber, “A Real-Time Approach to Stereopsis and Lane-Finding”, in proc of *IEEE Intelligent Vehicles Symposium 1996 (IEEE-IV 1996)*, pp. 207-212.

[**Theodoridis2006**] S. Theodoridis, K. Koutroumbas, “Pattern Recognition”, *Academic Press*, 2006, pp. 527-528.

[**Thorpe2002**] - C. Thorpe, R. Aufferre, J.D. Carlson, D. Duggins, T.W. Fong, J. Gowdy, J. Kozar, R. MacLachlan, C. McCabe, C. Mertz, A. Suppe, C. Wang, and T. Yata, “Safe Robot Driving”, in proc of *International Conference on Machine Automation 2002 (ICMA 2002)*.

[**Trucco1998**] E. Trucco and A. Verri, “Introductory Techniques for 3-D Computer Vision”, *Prentice-Hall*, 1998.

[**Trzebiatowski2004**] – M. S. von Trzebiatowski, A. Gern, U. Franke, U. Kaeppler, P. Levi, “Detecting Reflection Posts – Lane Recognition on Country Roads”, in proc of *IEEE Intelligent Vehicles Symposium 2004 (IEEE-IV 2004)*, pp. 304-309.

[**Vancea2006**] – C. Vancea, S. Nedevschi, ”Analysis of different image rectification approaches for binocular stereovision systems”, in proc of *IEEE 2nd International Conference on Intelligent Computer Communication and Processing 2006 (IEEE-ICCP 2006)*, pp. 135-142.

[**Weber1996**] - J. Weber, M. Atkin, “Further Results on the Use of Binocular Vision for Highway Driving”, in proc of *SPIE 1996, Vol. 2902: Transportation Sensors and Controls: Collision Avoidance, Traffic Management, and ITS*, pp. 52-61.

**[Williamson1998]** T. A. Williamson, “A high-performance stereo vision system for obstacle detection”, *PhD Thesis CMU-RI-TR-98-24, Robotics Institute Carnegie Mellon University*, Pittsburg, September 1998.

**[Yu1997]** – B. Yu, A. K. Jain, “Lane Boundary Detection Using A Multiresolution Hough Transform”, in proc of *IEEE International Conference on Image Processing 1997 (ICIP 1997)*, vol. 2, pp. 748-751.

## Articole publicate în domeniul tezei

### În reviste internaționale cotate ISI

1. R. Danescu, S. Nedevschi, “Probabilistic Lane Tracking in Difficult Road Scenarios Using Stereovision”, *IEEE Transactions on Intelligent Transportation Systems*, vol. 10, No. 2, June 2009, ISSN 1524-9050, pp. 272-282. – **factor de impact 2.8 / 2008.**

### În volume de conferință indexate ISI (ISI Proceedings)

1. R. Danescu, F. Oniga, S. Nedevschi, M.-M. Meinecke, “Tracking Multiple Objects Using Particle Filters and Digital Elevation Maps”, in proc of *IEEE Intelligent Vehicle Symposium 2009 (IEEE-IV 2009)*, pp. 88-93.
2. R. Danescu, D. Lebu, F. Oniga, S. Nedevschi, M.-M. Meinecke, “A Flexible Solution for Detection and Tracking of Multiple Objects”, in proc of *IEEE International Conference on Intelligent Computer Communication and Processing 2009 (ICCP 2009)*, pp. 165-168.
3. S. Nedevschi, T. Marita, R. Danescu, F. Oniga, S. Bota, “On-board Stereo Sensor for Intersection Driving Assistance. Architecture and Specification”, in proc of *IEEE International Conference on Intelligent Computer Communication and Processing 2009 (ICCP 2009)*, pp. 409-416.
4. S. Nedevschi, R. Danescu, T. Marita, F. Oniga, C. Pocol, S. Bota, M.-M. Meinecke, M. A. Obojski, “Stereovision-Based Sensor for Intersection Assistance”, book chapter in *Advanced Microsystems for Automotive Applications, April 2009, Springer, ISBN 978-3-642-00744-6*, pp. 129-163.
5. F. Oniga, S. Nedevschi, R. Danescu, M.-M. Meinecke, “Global Map Building Based on Occupancy Grids Detected from Dense Stereo in Urban Environments”, in proc of *IEEE International Conference on Intelligent Computer Communication and Processing 2009 (IEEE-ICCP 2009)*, pp. 111-117.
6. R. Danescu, S. Nedevschi, M. M. Meinecke, T. B. To, “A Stereovision-Based Probabilistic Lane Tracker for Difficult Road Scenarios”, in proc of *IEEE Intelligent Vehicles Symposium 2008 (IV2008)*, pp. 536-541.
7. R. Danescu, S. Nedevschi, “Adaptive and Robust Road Tracking System Based on Stereovision and Particle Filtering”, in proc. of *IEEE International Conference on Intelligent Computer Communication and Processing 2008 (ICCP 2008)*, pp. 67-73.
8. S. Nedevschi, R. Danescu, T. Marita, F. Oniga, C. Pocol, S. Sobol, C. Tomiuc, C. Vancea, M.M. Meinecke, T. Graf, T. B. To, M.A. Obojski, “A Sensor for Urban Driving Assistance Systems Based on Dense Stereovision”, in proc of *IEEE Intelligent Vehicles Symposium 2007 (IEEE-IV 2007)*, pp. 276-283.
9. R. Danescu, S. Nedevschi, T. B. To, “A Stereovision-Based Lane Detector for Marked and Non-Marked Urban Roads”, in proc of *IEEE 3-rd International*



*Conference on Intelligent Computer Communication and Processing 2007 (IEEE-ICCP 2007)*, pp. 81-88.

10. R. Danescu, S. Nedevschi, M.M. Meinecke, T.B. To, "Lane Geometry Estimation in Urban Environments Using a Stereovision System", in proc of *IEEE Intelligent Transportation Systems Conference 2007 (ITSC 2007)*, pp. 271-276.
11. R. Danescu, S. Nedevschi, M.M. Meinecke, T. Graf, "Stereovision Based Vehicle Tracking in Urban Traffic Environments", in proc of *IEEE Intelligent Transportation Systems Conference 2007 (ITSC 2007)*, pp. 400-404.
12. S. Nedevschi, F. Oniga, R. Danescu, T. Graf, R. Schmidt, "Increased Accuracy Stereo Approach for 3D Lane Detection", in proc of *IEEE Intelligent Vehicles Symposium 2006 (IEEE-IV 2006)*, pp. 42-49.
13. S. Nedevschi, F. Oniga, R. Danescu, T. Graf, R. Schmidt, "Increased Accuracy Stereo Approach for 3D Lane Detection", in proc of *IEEE Intelligent Vehicles Symposium 2006, (IEEE-IV 2006)*, pp. 42-49.
14. S. Nedevschi, R. Danescu, T. Marita, F. Oniga, C. Pocol, S. Sobol, T. Graf, R. Schmidt, "Driving Environment Perception Using Stereovision", in proc of *IEEE Intelligent Vehicles Symposium 2005 (IEEE-IV2005)*, pp.331-336.
15. S. Nedevschi, R.Schmidt, T. Graf, R. Danescu, D. Frentiu, T. Marita, F. Oniga, C. Pocol, "3D Lane Detection System Based on Stereovision", in proc of *IEEE Intelligent Transportation Systems Conference 2004 (IEEE-ITSC 2004)*, pp. 161-166.
16. S. Nedevschi, R. Schmidt, T. Graf, R. Danescu, D. Frentiu, T. Marita, F. Oniga, C. Pocol, "High Accuracy Stereo Vision System for Far Distance Obstacle Detection", in proc of *IEEE Intelligent Vehicles Symposium 2004 (IEEE-IV 2004)*, pp.161-166.

**În volume ale conferințelor internaționale indexate în alte baze de date de referință (ieeexplore, citeseer)**

1. R. Danescu, S. Sobol, S. Nedevschi, T. Graf, "Stereovision-Based Side Lane and Guardrail Detection", in proc of *IEEE Intelligent Transportation Systems Conference 2006 (ITSC 2006)*, pp. 1156-1161.
2. S. Nedevschi, R. Danescu, D. Frentiu, T. Marita, F. Oniga, C. Pocol , "Spatial Grouping of 3D Points from Multiple Stereovision Sensors", in proc of *IEEE International Conference on Networking, Sensing and Control (ICNSC) 2004*, pp. 874-879.
3. S. Nedevschi, R. Danescu, D. Frentiu, T. Marita, F. Oniga, C. Pocol, Thorsten Graf, Rolf Schmidt, "High Accuracy Stereovision Approach for Obstacle Detection on Non-Planar Roads", *IEEE Intelligent Engineering Systems 2004 (IEEE-INES 2004)*, pp. 211-216.

### În volumul altor conferințe internaționale

1. S. Nedevschi, R. Danescu, T. Marita, F. Oniga, C. Pocol, S. Bota and C. Vancea, “A Sensor for Urban Driving Assistance Systems Based on Dense Stereovision”, book chapter in “*Stereo Vision*” editor A. Bhatti, published by *InTech Education and Publishing*, Vienna, November 2008, ISBN 978-953-7619-22-0, pp. 235-258.
2. S. Nedevschi, R. Danescu, C. Pocol, M. M. Meinecke, “Stereo Image Processing for ADAS and Pre-Crash Systems”, in proc of *5th International Workshop on Intelligent Transportation 2008 (WIT 2008)*, Hamburg; pp. 55-60.
3. S. Nedevschi, T. Marita, R. Danescu, F. Oniga, C. Pocol, S. Sobol, C. Tomiuc, C. Vancea, S. Bota, “Stereovision Sensor for Driving Assistance”, in proc of *IEEE 2-nd International Conference on Intelligent Computer Communication and Processing 2006 (IEEE-ICCP 2006)*, pp. 105-111.
4. R. Danescu, S. Nedevschi, “Robust Real-Time Lane Delimiting Features Extraction” , in proc of *IEEE 2-nd International Conference on Intelligent Computer Communication and Processing 2006 (IEEE-ICCP 2006)*, pp. 77-82.
5. S. Nedevschi, R. Danescu, T. Marita, F. Oniga, C. Pocol, “Moving Camera Rotation Estimation Using Horizon Line Features’ Motion Field”, in proc of *6-th International Carpathian Control Conference*, 2005, Lilafured-Miskolc, Hungary, pp.449-454, ISBN 963-661-645-0.
6. S. Nedevschi, R. Danescu, D. Frentiu, T. Marita, F. Oniga, C. Pocol, R. Schmidt, T. Graf, “Stereovision Approach For Obstacle Detection On Non-Planar Roads”, in proc of *1st International Conference on Informatics in Control, Automation and Robotics (ICINCO)*, 2004, Vol. 2, pp. 11-18.

### În reviste naționale cotate CNCSIS, categoria B

1. S. Nedevschi, R. Danescu, D. Frentiu, T. Marita, F. Oniga, C. Pocol, T. Graf, R. Schmidt, “High Accuracy Stereovision Approach for Obstacle Detection on Non-Planar Roads”, *Journal of Automation, Computers and Applied Mathematics (ACAM)*, Vol. 14, No. 2, 2005, pp. 173-178.
2. S. Nedevschi, T. Marita, M. Vaida, R. Danescu, D. Frentiu, F. Oniga, C. Pocol, “Camera Calibration Method for Stereo Measurements”, *Journal of Control Engineering and Applied Informatics (CEAI)*, Vol. 4, No. 2, 2002, pp. 21-28.

## Citări independente relevante

Un criteriu măsurabil al relevanței activității de cercetare prezentate în această teză poate fi numărul de citări ale lucrărilor noastre de-a lungul acestor ani. Citările următoare sunt extrase folosind (scholar.google.com). Am exclus auto-citările, și citările în lucrări mai puțin relevante. De asemenea, am selecționat doar lucrările care prezintă activitatea strict legată de subiectul acestei teze.

1. S. Nedeveschi, R. Schmidt, T. Graf, R. Danescu, D. Frentiu, T. Marita, F. Oniga, C. Pocol, “3D Lane Detection System Based on Stereovision”, in proc of *IEEE Intelligent Transportation Systems Conference 2004 (IEEE-ITSC 2004)*, pp. 161-166.

*Această lucrare prezintă soluția descrisă în capitolul 5.1.*

### Citări:

McCall, J.C, Trivedi, M.M., “Video-based lane estimation and tracking for driver assistance: survey, system, and evaluation”, *IEEE Transactions on Intelligent Transportation Systems*, Vol 7, Issue 1, March 2006, pp. 20-37. - **ISI**

C. Hoffmann, T. Dang, “Cheap Joint Probabilistic Data Association filters in an Interacting Multiple Model design”, *Robotics and Automation Systems*, Vol. 57, Issue 3, March 2009, pp. 268-278. – **ISI**

S. Y. Cheng, M. M. Trivedi, “Lane tracking with omnidirectional cameras: algorithms and evaluation”, *EURASIP Journal on Embedded Systems*, 2007 - **ISI**

S. J. Tsai, T. Y. Sun, “The robust and fast approach for vision-based shadowy road boundary detection”, in proc *IEEE Intelligent Vehicles Symposium 2005 (IEEE-IV 2005)*, pp. 486-491.

P. Lombardi, M. Zanin, S. Messelodi, “Unified stereovision for ground, road, and obstacle detection”, in proc *IEEE Intelligent Vehicles Symposium 2005 (IEEE-IV 2005)*, pp. 783-788.

L. W. Tsai, J. W. Hsieh, C. H. Chuang, K. C. Fan, “Lane detection using directional random walks”, in proc *IEEE Intelligent Vehicles Symposium 2008 (IEEE-IV 2008)*, pp. 303-306.

B. S. Reddy, O. A. Basir, S. J. Leat, “Estimation of driver attention using Visually Evoked Potentials”, in proc *IEEE Intelligent Vehicles Symposium 2007 (IEEE-IV 2007)*, pp. 588-593.

2. S. Nedeveschi, R. Danescu, D. Frentiu, T. Marita, F. Oniga, C. Pocol, Thorsten Graf, Rolf Schmidt, “High Accuracy Stereovision Approach for Obstacle Detection on Non-Planar Roads”, in proc of *IEEE Intelligent Engineering Systems 2004 (INES 2004)*, pp. 211-216.

*Această lucrare prezintă parțial metodele descrise în capitolul 5.1, fiind prima descriere a metodei de detecție a profilului vertical și a separării trăsăturilor obstacolelor de trăsăturile de drum.*

**Citări:**

A. Broggi, C. Caraffi, P. P. Porta, P. Zani, “The Single Frame Stereo Vision System for Reliable Obstacle Detection Used during the 2005 DARPA Grand Challenge on TerraMax”, in proc of *IEEE Intelligent Transportation Systems Conference 2006 (IEEE-ITSC 2006)*, pp. 745-752.

A. Wedel, U. Franke, H. Badino, D. Cremers, “B-spline modeling of road surfaces for freespace estimation”, in proc of *IEEE Intelligent Vehicles Symposium 2008 (IEEE-IV 2008)*, pp. 828-833.

Caraffi, C, Cattani, S, Grisleri, P, “Off-Road Path and Obstacle Detection Using Decision Networks and Stereo Vision”, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 8, Issue 4, December 2007, pp. 607-618. - **ISI**

D. Fernandez, I. Parra, M. A. Sotelo, P. Revenga, S. Alvarez, M. Gavilan, “3D Candidate Selection Method for Pedestrian Detection on Non-Planar Roads”, in proc of *IEEE Intelligent Vehicles Symposium 2007 (IEEE-IV 2007)*, pp. 1162-1167.

A. D. Sappa, R. Herrero, F. Dornaika, D. Geronimo, A. Lopez, “Road Approximation in Euclidean and v-Disparity Space: A Comparative Study”, *Lecture Notes in Computer Science*, vol. 4739, 2007, Springer, pp. 1105-1112.

D. Gerónimo, A. M. López, A. D. Sappa, T. Graf, "Survey on Pedestrian Detection for Advanced Driver Assistance Systems", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 21 May 2009 (preprint). - **ISI**

**3.** R. Danescu, S. Sobol, S. Nedevschi, T. Graf, “Stereovision-Based Side Lane and Guardrail Detection”, in proc of *IEEE Intelligent Transportation Systems Conference 2006 (ITSC 2006)*, pp. 1156-1161.

*Această lucrare prezintă metoda de detecție a benzilor adiacente, prezentată în capitolul 5.1*

**Citări:**

A. D. Sappa, F. Dornaika, D. Ponsa, D. Geronimo, A. Lopez, “An Efficient Approach to Onboard Stereo Vision System Pose Estimation”, *IEEE Transactions on Intelligent Transportation Systems*, Vol. 9, Issue 3, September 2008, pp. 476-490. – **ISI**

**4.** R. Danescu, S. Nedevschi, M. M. Meinecke, T. B. To, “A Stereovision-Based Probabilistic Lane Tracker for Difficult Road Scenarios”, in proc of *IEEE Intelligent Vehicles Symposium 2008 (IEEE-IV 2008)*, pp. 536-541.

*Această lucrare prezintă soluția de urmărire a drumului prezentată în capitolul 5.3.*

**Citări:**

H. Loose, U. Franke, C. Stiller, "Kalman Particle Filter for Lane Recognition on Rural Roads", in proc of *IEEE Intelligent Vehicles Symposium 2009 (IEEE-IV 2009)*, pp. 60-65.