

TEZA DE DOCTORAT

Contribuții la concepția unui sistem îmbarcat pe automobile pentru protecția pietonilor

Autor: Teodor-Cosmin Dehelean
Conducător de doctorat: Prof. dr. ing. Corina Naforniță

Seriile Teze de doctorat ale UPT sunt:

- | | |
|---|--|
| 1. Automatică | 9. Inginerie Mecanică |
| 2. Chimie | 10. Știința Calculatoarelor |
| 3. Energetică | 11. Știința și Ingineria Materialelor |
| 4. Ingineria Chimică | 12. Ingineria sistemelor |
| 5. Inginerie Civilă | 13. Inginerie energetică |
| 6. Inginerie Electrică | 14. Calculatoare și tehnologia informației |
| 7. Inginerie Electronică și Telecomunicații | 15. Ingineria materialelor |
| 8. Inginerie Industrială | 16. Inginerie și Management |

Universitatea Politehnica Timișoara a inițiat seriile de mai sus în scopul diseminării expertizei, cunoștințelor și rezultatelor cercetărilor întreprinse în cadrul Școlii doctorale a universității. Seriile conțin, potrivit H.B.Ex.S Nr. 14 / 14.07.2006, tezele de doctorat susținute în universitate începând cu 1 octombrie 2006.

Copyright © Editura Politehnica – Timișoara, 2013

Această publicație este supusă prevederilor legii dreptului de autor. Multiplicarea acestei publicații, în mod integral sau în parte, traducerea, tipărirea, reutilizarea ilustrațiilor, expunerea, radiodifuzarea, reproducerea pe microfilme sau în orice altă formă este permisă numai cu respectarea prevederilor Legii române a dreptului de autor în vigoare și permisiunea pentru utilizare obținută în scris din partea Universității Politehnica Timișoara. Toate încălcările acestor drepturi vor fi penalizate potrivit Legii române a drepturilor de autor.

România, 300159 Timișoara, Bd. Republicii 9,
Tel./fax 0256 403823
e-mail: editura@edipol.upt.ro

Cuvânt înainte

Teza de doctorat a fost elaborată pe parcursul activității mele în cadrul Departamentului de Comunicații al Universității Politehnica Timișoara.

Mulțumiri deosebite se cuvin conducătoarei de doctorat, prof. dr. ing. Corina Naforniță, care m-a îndrumat cu mult profesionalism și cu o porție consistentă de răbdare pe parcursul întregii perioade de cercetare. Doresc să-i mulțumesc și pentru cuvintele încurajatoare pe parcursul celor cinci ani de colaborare în acest proiect, care m-au ajutat decisiv să îmi mențin interesul științific dar și motivația de a continua. Nu în ultimul rând țin să-i mulțumesc pentru momentele deosebite, în special pentru multele momente vesele pe care am avut șansa să le trăim împreună, fie la conferințe, la facultate sau online.

Soției mele iubite, Melanie, doresc să îi promit că voi reechilibra balanța dintre timpul afectat ei și cel pentru „alte ocupații”. Fără sprijinul ei nu aș fi putut obține aceste rezultate și finaliza această lucrare.

Doresc să-i mulțumesc mamei mele, Florica, pentru cadoul deosebit pe care mi l-a făcut cu mult timp în urmă!

Timișoara, iunie 2021

Teodor-Cosmin Dehelean

Copiilor mei dragi, MINA și NIKLAS

„Der Weg ist das Ziel!”

Dehelean, Teodor-Cosmin

Contribuții la concepția unui sistem imbarcat pe automobile pentru protecția pietonilor

Teze de doctorat ale UPT, Seria X, Nr. YY, Editura Politehnica, 2021, 102 pagini, 58 figuri, 5 tabele.

Cuvinte cheie:

metrică OSPA, distanța Mahalanobis, obiect extins, radar, efect micro-Doppler

Rezumat:

Contribuția originală a acestei teze de doctorat constă în primul rând în introducerea unei metrici noi, numită M-OSPA, care ia în considerare nivelul de incertitudine corespunzător observațiilor prelevate de un radar la un moment dat. Teza analizează în detaliu beneficiile noii metrici, în ipoteza reprezentării extinse a obiectelor din zona de acoperire. Metoda OSPA este dezvoltată prin înlocuirea distanței euclidiene cu distanță Mahalanobis ca și distanță de bază între două puncte ale spațiului de stări. Distanța Mahalanobis corespunde distanței dintre un punct determinist, reprezentând poziția reală, și o variabilă statistică, reprezentând poziția estimată de către radar. Pentru a reduce complexitatea computațională necesară pentru calculul M-OSPA, teza propune considerarea factorului de formă a diferitelor categorii de ținte, obținându-se astfel o scădere a timpului de calcul cu 20%.

CUPRINS

REZUMAT	10
1 INTRODUCERE	12
2 SISTEME RADAR	18
2.1 Tipuri de radare în autovehicule	18
2.2 Distanța senzor – țintă	19
2.3 Viteza relativă între radar și obiectul – țintă	20
2.4 Poziția unghiulară a unui obiect – țintă	23
2.5 Radarul cu undă continuă modulată în frecvență (FMCW)	25
2.6 Efectul micro – Doppler	26
3 TEHNICI DE PROCESARE A SEMNALELOR RADAR.....	28
3.1 Bazele prelucrării numerice a semnalelor radar	28
3.2 Procesorul de semnal radar.....	31
3.3 Detecția bazată pe limita CFAR.....	34
3.4 Percepția țintelor în mișcare.....	37
3.5 Procesarea impuls – Doppler.....	38
3.6 Compressive sensing	40
3.7 Estimarea parametrilor unui obiect	48
4 ALGORITMI DE TRACKING	50
4.1 Modele de mișcare a țintelor punctiforme	50
4.1.1 Modele de mișcare uniformă	51
4.1.2 Modele de mișcare propulsată	52
4.1.3 Modele de mișcare planară	56
4.2 Filtrele Kalman	59
4.3 Algoritmi de urmărire a țintelor extinse	61
5 EVALUAREA PERFORMANȚELOR ALGORITMILOR DE TRACKING.....	65
5.1 Metrici CLEAR.....	66
5.2 Distanțe de bază	68
5.3 Metoda OSPA	71
5.4 Mulțimi de valori finite aleatorii	74
5.5 Filtre pentru ținte singulare.....	75
5.6 Filtre PHD	77
5.6.2 Filtrul CPHD	79
5.6.3 Filtrul SMC-PHD.....	81
5.7 Filtrul CB-MB.....	82
5.8 M-OSPA cu factor de formă pentru ținte extinse	84
5.9 Simulări și rezultate.....	85
6 CONCLUZII	94
7 BIBLIOGRAFIE.....	97

LISTĂ DE FIGURI

Figura 1: Tipuri diferite de senzori în autovehicule, sursă: aptiv.com	12
Figura 2: Radarele funcționează indiferent de condițiile meteo, sursă: aptiv.com ..	13
Figura 3: Detecția unui pieton ascuns, sursă: aptiv.com	14
Figura 4: Schema bloc a unui sistem radar.....	16
Figura 5: Funcții necesare pentru vehiculele autonome	16
Figura 6: Tipuri de radare în autovehicule	18
Figura 7: Principiul de măsurare a distanței până la obiectul – țintă	19
Figura 8: Variația frecvenței, datorată vitezei relative între radar și țintă	20
Figura 9: Semnal transmis și recepționat de un radar FMCW	21
Figura 10: Tren de impulsuri în semnalul de transmisie	22
Figura 11: Analiza semnalului radar la receptor	22
Figura 12: Cubul de date al unui radar automotive.....	23
Figura 13: Poziția unghiulară a obiectelor.....	24
Figura 14: Exemplu de layout al elementelor antenelor în radare automotive	24
Figura 15: Efectul neliniarității în frecvență a semnalului FMCW	25
Figura 16: Efectul micro – Doppler, cauzat de un pieton	26
Figura 17: Spectrul multiplicat al unui semnal complex eșantionat	29
Figura 18: Prelucrarea la receptor a semnalului radar cu valori complexe.....	30
Figura 19: Schema bloc a unui receptor radar	30
Figura 20: Procesorul de semnal radar S32R45, sursă NXP	31
Figura 21: Schema funcțională a unui procesor numeric de semnal radar.....	32
Figura 22: Algoritm de detecție CFAR.....	35
Figura 23: Fereastra CFAR unidimensională, sursă [8]	36
Figura 24: Efectul filtrării MTI „trece sus”, sursă [8]	38
Figura 25: Procesare impuls-Doppler.....	39
Figura 26: Harta impuls-Doppler pentru nouă ținte, sursă [24]	39
Figura 27: Semnal fără zgomot. Sus: componenta în fază a impulsului 256 – original și cu N/4 eșantioane prelevate neuniform marcate cu verde. Mijloc: semnal reconstruit cu l1-magic. Jos: semnal reconstruit cu OMP. Axa x în [s].....	42
Figura 28: Semnal cu zgomot. Sus: componenta în fază a impulsului 256 – original și cu N/4 eșantioane prelevate neuniform marcate cu verde. Mijloc: semnal reconstruit cu l1-magic. Jos: semnal reconstruit cu OMP. Axa x în [s].....	42
Figura 29: Semnal fără zgomot – domeniul frecvență, după prima și respectiv a doua transformare FFT. Sus este reprezentat cazul tradițional cu eșantionare uniformă. La mijloc și jos, cazul reconstrucției compressive sensing pentru N/4 eșantioane. Stânga, prima transformare FFT pentru semnalul original, reconstruit cu l1-magic și reconstruit cu OMP. Dreapta, a doua transformare FFT, pentru celula de rezoluție cu două ținte aflate la aceeași distanță (R = 65 m), dar cu viteze diferite, pentru semnalul original, reconstruit cu l1-magic și reconstruit cu OMP. Axa x în [Hz].....	43
Figura 30: Semnal afectat de zgomot – domeniul frecvență, după prima și respectiv a doua transformare FFT. Sus este reprezentat cazul tradițional cu eșantionare uniformă. La mijloc și jos, cazul reconstrucției compressive sensing pentru N/4 eșantioane. Stânga, prima transformare FFT pentru semnalul original, reconstruit cu l1-magic și reconstruit cu OMP. Dreapta, a doua transformare FFT, pentru celula de rezoluție cu două ținte aflate la aceeași distanță (R = 65 m), dar cu viteze diferite, FFT pentru semnalul original, reconstruit cu l1-magic și reconstruit cu OMP. Axa x în [Hz].	44

Figura 31: Semnal fără zgomot – domeniul frecvența, după prima și respectiv a doua transformare FFT. Sus este reprezentat cazul tradițional cu eșantionare uniformă. La mijloc și jos, cazul reconstrucției compressive sensing pentru $N/8$ eșantioane. Stânga, prima transformare FFT pentru semnalul original, reconstruit cu l1-magic și reconstruit cu OMP. Dreapta, a doua transformare FFT, pentru celula de rezoluție cu două ținte aflate la aceeași distanță ($R = 65$ m), dar cu viteze diferite, pentru semnalul original, reconstruit cu l1-magic și reconstruit cu OMP. Axa x în [Hz].....	46
Figura 32: Diagrama distanță-Doppler pentru semnalul fără zgomot, eșantionare uniformă.....	47
Figura 33: Diagrama distanță-Doppler pentru semnal cu zgomot, eșantionare uniformă.....	47
Figura 34: Diagrama distanță-Doppler pentru semnalul fără zgomot, reconstrucție l1-magic, $N/4$ eșantioane prelevate neuniform	47
Figura 35: Diagrama distanță-Doppler pentru semnalul cu zgomot, reconstrucție l1-magic, $N/4$ eșantioane prelevate neuniform.....	47
Figura 36: Diagrama distanță-Doppler pentru semnalul fără zgomot, reconstrucție OMP, $N/4$ eșantioane prelevate neuniform	48
Figura 37: Diagrama distanță-Doppler pentru semnalul cu zgomot, reconstrucție OMP, $N/4$ eșantioane prelevate neuniform	48
Figura 38: Distribuții gamma ale probabilităților de sejur în procese semi-Markov	55
Figura 39: Traectoria unei ținte în coordonate 2D, sursă [36]	56
Figura 40: Schema bloc a unui filtru Kalman	60
Figura 41: Niveluri de complexitate în modelarea conturului unei ținte	63
Figura 42: Urmărirea țintelor extinse caracterizate de câte trei puncte (CLR). Axele în [m]......	64
Figura 43: Urmărirea țintelor multiple	65
Figura 44: Metrica Hausdorff	66
Figura 45: Variația MOTA în cazul unui scenariu cu o singură țintă	68
Figura 46: Punctele de intersecție între două distribuții normale.	71
Figura 47: Variația OSPA într-o situație de trafic.....	73
Figura 48: Filtru PHD cu două ținte, coordonate în metri.....	77
Figura 49: Manevră de parcare cu patru autovehicule. Cercurile indică locul în care țintele apar în câmpul de acoperire, iar triunghiurile indică locul în care țintele dispar. Axele în [cm].	86
Figura 50: Manevră de parcare cu patru autovehicule, sus: poziția x, jos: poziția y pentru fiecare punct reprezentativ (punctul cel mai la stânga, cel mai apropiat și cel mai la dreapta) per țintă. Timpul este exprimat în cicluri radar.	86
Figura 51: Filtrul EKF-PHD, sus: eroare de localizare OSPA, jos: eroare de localizare M-OSPA cu factor de formă; Σ_{Y1} în negru, Σ_{Y2} în roșu, Σ_{Y3} în albastru, Σ_{Y4} în cyan. Timpul este exprimat în cicluri radar.....	88
Figura 52: Filtrul EKF-CPHD, sus: eroare de localizare OSPA, jos: eroare de localizare M-OSPA cu factor de formă; Σ_{Y1} în negru, Σ_{Y2} în roșu, Σ_{Y3} în albastru, Σ_{Y4} în cyan. Timpul este exprimat în cicluri radar.....	89
Figura 53: Filtrul SMC-CB-MB, sus: eroare de localizare OSPA, jos: eroare de localizare M-OSPA cu factor de formă; Σ_{Y1} în negru, Σ_{Y2} în roșu, Σ_{Y3} în albastru, Σ_{Y4} în cyan. Timpul este exprimat în cicluri radar.....	89
Figura 54: Simularea a trei ținte (mașina A-verde, B-albastru, respectiv C-cyan) într-un scenariu cu intersecții. Cercurile indică locul în care țintele apar în câmpul de acoperire, iar triunghiurile indică locul în care țintele dispar. Axele în [cm].	90

Figura 55: Trei ținte cu intersecții, sus: poziția x, jos: poziția y pentru fiecare punct reprezentativ (punctul cel mai la stânga, cel mai apropiat și cel mai la dreapta) per țintă. Timpul este exprimat în cicluri radar.....	91
Figura 56: Filtru EKF-PHD, scenariul 2, sus: eroare de localizare OSPA, jos: eroare de localizare M-OSPA cu factor de formă; Σ_{Y1} în negru, Σ_{Y2} în roșu, Σ_{Y3} în albastru, Σ_{Y4} în cyan. Timpul este exprimat în cicluri radar.	91
Figura 57 Filtru EKF-CPHD, scenariul 2, sus: eroare de localizare OSPA, jos: eroare de localizare M-OSPA cu factor de formă; Σ_{Y1} în negru, Σ_{Y2} în roșu, Σ_{Y3} în albastru, Σ_{Y4} în cyan. Timpul este exprimat în cicluri radar.	92
Figura 58: Filtrul SMC-CB-MB, scenariul 2, sus: eroare de localizare OSPA, jos: eroare de localizare M-OSPA cu factor de formă; Σ_{Y1} în negru, Σ_{Y2} în roșu, Σ_{Y3} în albastru, Σ_{Y4} în cyan. Timpul este exprimat în cicluri radar.	93

LISTĂ DE TABELE

Tabel 1: MSE pentru metodele de reconstrucție cu compressive sensing	44
Tabel 2: Timpii de calcul pentru cei doi algoritmi compressive sensing	45
Tabel 3: Matricile de covarianță pentru cei patru algoritmi analizați	70
Tabel 4: Distanțele Mahalanobis D_m respectiv euclidiană D_e pentru algoritmi analizați (Tracker1-4) cu poziții reale variind în jurul $(0,0,0)^T$	70
Tabel 5: Avantajele metodei OSPA-T față de MOTA/MOTP, în opt scenarii diferite	73

REZUMAT

Algoritmii de urmărire concomitentă a unui număr mare de obiecte de interes sunt folosiți frecvent în diferite domenii științifice sau tehnice, cum ar fi biologia moleculară, sisteme de transport, în aplicații militare sau în robotică [52], [84] și [98]. Pentru senzorii imbarcați pe autoturisme, funcția centrală a acestora constă în detecția categoriilor diferite de ținte, de exemplu autoturisme, pietoni sau bicicliști, având la intrare o mulțime de semnale perturbate de zgomot și interferențe. Pe durata prezenței acestor ținte în câmpul de acoperire al sensorului, traiectoriile corespunzătoare fiecărei ținte sunt urmărite iterativ, de la momentul intrării acestora în zona de acoperire până la dispariția lor.

Luând în considerare proprietățile particulare ale modelelor de mișcare pentru fiecare categorie de ținte, metodele aplicate pentru detecție și urmărire variază și permit diferențierea între categorii, de exemplu între autoturisme și participanți vulnerabili la trafic [99]. Ca urmare a îmbunătățirii remarcabile obținută în ultimii ani în ceea ce privește rezoluția de localizare a radarelor automotiv, reprezentarea obiectelor urmărite a devenit mai exactă dar și mai complexă, dat fiind faptul că fiecărei ținte îi sunt atribuite mai multe puncte caracteristice, aflate de regulă la extremitățile sale geometrice. Setul de puncte reprezentative este monitorizat pe întreaga perioadă de observație [60], [100].

Pentru a elimina dezavantajele legate de problema de asociere între observațiile prelevate la un moment dat și obiectele reale, Mahler a introdus în [88] un model matematic nou, utilizat între timp din ce în ce mai des în algoritmii de tracking automotiv. Acesta are la bază reprezentarea stărilor reale și a celor estimate sub forma unor mulțimi de date aleatoare (RFS). Modelul aplică un principiu similar cu cel al filtrelor Bayes sau Kalman, compus din două etape iterative, prima de predicție și a doua de corecție. Spre deosebire de filtrul Kalman, acest model propagă între iterații funcția de intensitate statistică a-posteriori a RFS, respectiv momentul statistic de ordin întâi al RFS, numit și densitatea de probabilitate a ipotezelor (PHD). O metodă eficientă și intuitivă de evaluare a performanțelor filtrelor PHD, numită OSPA, a fost introdusă în [73] și optimizată în [74].

Contribuția originală a acestei teze de doctorat constă în primul rând în introducerea unei metrici noi, numită M-OSPA, care ia în considerare nivelul de incertitudine corespunzător observațiilor prelevate de un radar la un moment dat. În cazul evaluării algoritmilor de tracking pe baza M-OSPA este posibilă diferențierea între sistemele radar care efectuează măsurători "corecte întâmplător," și cele care determină sistematic stările reale ale țintelor urmărite, cu un nivel ridicat de certitudine. Teza analizează în detaliu beneficiile noii metrici, în ipoteza reprezentării extinse a obiectelor din zona de acoperire. Metoda OSPA este dezvoltată prin înlocuirea distanței euclidiene cu distanța Mahalanobis ca și distanță de bază între două puncte ale spațiului de stări. Distanța Mahalanobis corespunde distanței dintre un punct determinist, reprezentând poziția reală, și o variabilă statistică, reprezentând poziția estimată de către radar. Pentru a reduce complexitatea computațională necesară pentru calculul M-OSPA, teza propune considerarea factorului de formă a

diferitelor de categorii de ținte, obținându-se astfel o scădere a timpului de calcul cu 20%.

Necesitatea de a considera componentele matricii de covarianță în estimarea capabilității de tracking a unui algoritm dat este demonstrată printr-un număr mare de rezultate experimentale, obținute cu trei categorii de filtre PHD: EKF-PHD, EKF-CPHD și SMC-CB-MB.

Metodele propuse au o relevanță practică deosebită, ele fiind deja utilizate pentru validarea sistemelor radar Gen5, dezvoltate și produse de către compania Veoneer și îmbarcate în autoturismele Mercedes-Benz de ultimă generație.

Doi algoritmi de compressive sensing sunt analizați comparativ, reprezentând o altă contribuție personală a acestei teze. Ei permit reducerea considerabilă a volumului de date utile, fără pierderi semnificative de informație. Modelele matematice și rezultatele simulărilor efectuate sunt prezentate în detaliu.

Urmărind în continuare evoluția tehnologică a sistemelor radar îmbarcate pe autoturisme, autorul propune în perspectivă următoarele direcții de cercetare teoretică și experimentală:

- utilizarea M-OSPA în scenarii cu modele de mișcare 3D,
- utilizarea M-OSPA în scenarii cu modele de observație 3D,
- compressive sensing utilizând transformate wavelet.

1 INTRODUCERE

La prima vedere s-ar părea că cea mai mare provocare a mașinilor autonome este reprezentată de dezvoltarea algoritmilor care să indice traiectoria optimă de deplasare a autovehiculului. Acest lucru nu este adevărat! Problema centrală constă în perceperea informațiilor din mediului înconjurător și implicit în crearea unui sistem de senzori care poate construi un model al mediului înconjurător cât mai precis și mai robust, pe baza căruia pot funcționa algoritmi de navigare și control. Din acest motiv, sistemele de percepție sunt esențiale pentru grade ridicate de automatizare a autoturismelor. Producătorii de autovehicule doresc să identifice cele mai bune sisteme de percepție a mediului înconjurător îmbarcate în mașini, reușind astfel să realizeze funcții de siguranță activă care să salveze vieți omenești. Sensorii radar oferă o multitudine de avantaje în acest context, incluzând de exemplu costul redus al sistemelor și funcționarea performantă independent de condițiile meteo exterioare, cum ar fi gradul de luminozitate, nivelul de precipitații sau condițiile de vizibilitate. Aceste atribute fac sensorii radar să reprezinte o bază ideală pentru crearea modelului de mediu înconjurător în orice mașină, devenind din ce în ce mai importanți pe măsură ce funcțiile îmbarcate evoluează de la simple avertizări ale șoferului către funcții de asistare, intervenție și control.

Sistemele radar moderne îmbarcate pe automobile oferă soluții excepționale pentru navigarea autonomă. Atât producătorii de autoturisme cât și furnizorii de componente electronice sunt într-o competiție continuă pentru a îndeplini cerințele în creștere legate de nivelul de siguranță al mașinii, în paralel cu reducerea costurilor de producție a echipamentelor, permițând astfel prețuri acceptabile pentru consumatori și în același timp o acoperire accelerată a pieței. La nivelul senzorilor din autovehicule, acest lucru implică un raport preț / performanță foarte bine echilibrat între camere video, sisteme radar și tehnologii lidar, considerând atât punctele forte cât și cele relativ slabe.




Figura 1: Tipuri diferite de senzori în autovehicule, sursă: aptiv.com

Tipurile principale de senzori utilizați în mașini sunt radare și camere video (Figura 1), în timp ce senzori ultrasonici au un rol important la viteze și distanțe reduse, iar sensorii lidar [1], [2], [3] sunt des folosiți pentru navigare autonomă. Unul din motivele pentru care radarele sunt folosite foarte des constă în faptul că pot indica

În mod fiabil la ce distanță se află un obiect țintă. Un senzor radar de distanță lungă îmbarcat în automobil poate localiza cu precizie un obiect aflat la 300 sau chiar 500 de metri distanță. Spre deosebire de acesta, camerele video estimează distanță până la un obiect țintă pe baza dimensiunii obiectului raportată la dimensiunea întregii imagini. Chiar și folosind camere stereo, acest lucru rămâne deosebit de complicat, în special la distanțe mari. În plus rezoluția devine un factor limitant major, deoarece un pixel singular este dificil de diferențiat în cazul unor obiecte îndepărtate. Obiective optice de focalizare pot contracara acest dezavantaj, însă acestea reduc considerabil câmpul de acoperire al camerei video, necesitând astfel un compromis între rezoluție, distanță și costuri. Radarele îmbarcate în autovehicule determină concomitent și viteza relativă a obiectelor din câmpul de acoperire, furnizând în paralel cu poziția unui obiect și informațiile legate de cât de repede se apropie sau se depărtează acesta față de sistemul de referință. Camerele video și senzorii lidar au nevoie de regulă de mai multe imagini într-un anumit interval de timp pentru a putea estima viteza relativă.



Figura 2: Radarele funcționează indiferent de condițiile meteo, sursă: aptiv.com

Deoarece radarul folosește unde radio în locul luminii pentru a detecta obiecte, acesta funcționează foarte bine în condiții de ploaie, ceață, zăpadă sau fum (Figura 2). Spre deosebire de camerele video, radarele nu necesită un contrast ridicat sau iluminare pentru a funcționa corect în timpul nopții. Un avantaj adițional major oferit producătorilor de autoturisme este flexibilitatea poziției de montare a sistemelor radar în mașină, chiar și în spatele unor suprafețe opace. Senzorii bazați pe tehnologii optice trebuie să "vadă" șoseaua, ceea ce înseamnă că aceștia trebuie instalați într-un punct cât mai înalt al mașinii, care permite sistemului o vedere optimă și o protecție adecvată împotriva murdăriei de pe șosea. Spre deosebire de aceștia, radarele pot fi montate în spatele grilajelor, integrate în barele de protecție sau ascunse în alt fel, oferind designerilor grade mari de libertate în estetica autoturismelor.

Camerele video sunt foarte potrivite pentru clasificarea obiectelor. Doar o cameră poate detecta și interpreta semnele de circulație. De asemenea ea reprezintă sistemul optim pentru a stabili dacă obiectul țintă este alt autovehicul, un pieton, o bicicletă sau chiar eventual un cățel. Fiecare dintre obiectele menționate se comportă diferit, astfel că sistemul de percepție va fi mai performant în a anticipa traiectoria obiectului țintă în cazul în care poate clasifica cu precizie tipul de obiect urmărit.

Senzorii lidar au o lungime de undă mult mai mică decât radarele tradiționale, având implicit o rezoluție unghiulară net superioară și permițând astfel o detecție

exactă a contururilor țintelor. Din păcate, senzorii lidar necesită o suprafață curată și transparentă, dificil de asigurat pe întreaga durată de viață a autoturismelor. În plus tehnologia lidar este mai puțin matură, ceea ce înseamnă că este relativ scumpă. Prețul ridicat este în momentul de față factorul principal care limitează adoptarea acestora pe scară largă pe piața autoturismelor.

Detecția pietonilor [4] este dificilă pentru toate tipurile de senzori, în special într-un mediu urban în care pietonii pot traversa șoseaua și își pot schimba des direcția de deplasare. Metodele avansate de prelucrare a semnalelor radar îmbunătățesc considerabil capacitatea de detecție a pietonilor în scenarii cu zgomot ridicat, permițând recunoașterea acestora chiar și în cazul unei persoane ascunse, aflată de exemplu în spatele unei mașini parcate sau în spatele unei clădiri (Figura 3).




Figura 3: Detecția unui pieton ascuns, sursă: aptiv.com

În ultimii ani, clasificarea obiectelor VRU (vulnerable road user), adică a pietonilor, bicicliștilor și a conducătorilor de motociclete, a fost investigată pe scară largă, sugerând că semnăturile micro-Doppler (a se vedea capitolul 2.6) sunt promițătoare pentru diferențierea țintelor. Este bine cunoscut faptul că mișcarea relativă dintre radar și ținta induce efectul Doppler. Mișcarea relativă aici înseamnă, în general, mișcarea corpului principal (adică trunchiul pietonal, cadrul bicicletei) față de radar. Pe lângă mișcarea principală a corpului, există mișcări relative între componente radar și țintă, cum ar fi oscilația periodică a picioarelor / brațelor, rotația roților / pedalelor bicicletei pentru țintele VRU. Efectul Doppler indus de acele mișcări relative dintre componente radar și țintă este denumit de obicei în literatură efectul Micro-Doppler [5]. Pentru a utiliza datele provenite din detecția fenomenului micro-Doppler în clasificarea VRU, amprenta micro-Doppler este descompusă în valori singulare (SVD), iar parametrii astfel obținuți sunt evaluați ulterior. Una din matricile rezultate din descompunerea SVD conține informații dependente de timp, care permit estimarea perioadei mișcării micro-Doppler. O altă matrice conține informații legate de varianța și simetria micro-Doppler, pe baza cărora se poate stabili relația dintre diferitele părți mobile ale țintelor.

Pe măsură ce organismele de reglementare elimină treptat radarul automotive în banda de 24GHz din ce în ce mai aglomerată [6], acestea permit pe de altă parte utilizarea frecvențelor din banda de 77GHz (76 până la 81GHz), antrenând astfel avansul tehnologic al sistemelor radar cu undă continuă modulată în frecvență (FMCW, a se vedea capitolul 2.5). Extinderea frecvențelor disponibile permite o lățime de bandă a semnalelor transmise de până la 5GHz, în timp ce radarele de 24GHz sunt limitate la 200MHz. Acest lucru înseamnă o îmbunătățire de până la 25 de ori a rezoluției de măsurare a distanței, oferind deci o capacitate net superioară de detecție

și separație a obiectelor imediat învecinate. Abilitatea de a distinge între obiecte, de exemplu între un vehicul și un pieton, bazată pe caracteristicile tipice de mișcare a claselor de obiecte în cauză este esențială pentru luarea deciziilor automatizate de ordin superior.

Ca și principiu de măsură, radarele îmbarcate în autovehicule au rolul de a detecta distanța până la un obiect – țintă, viteza relativă între senzor și țintă, precum și unghiurile de azimut respectiv de elevație ale fiecărei ținte urmărite. Pentru a îmbunătăți capacitatea de măsură a unuia dintre acești parametri, sunt necesare de regulă compromisuri referitor la ceilalți parametri, având în vedere că resursele de calcul ale procesorului numeric de semnal sunt limitate. Gestionarea acestor compromisuri rămâne o problemă centrală a echipelor de dezvoltare de sisteme radar moderne în special în ceea ce privește rezoluția unghiulară, aceasta fiind un element cheie pentru diferențierea mașinilor din benzile vecine. O rezoluție foarte bună a unghiului de azimut, sub 1° sau chiar până la 0.1° , permite implementarea unor funcții de conducere automată a mașinii, ca de exemplu controlul adaptiv al vitezei de croazieră (adaptive cruise control, ACC) sau frânarea automată în caz de urgență (autonomous emergency break, AEB). Necesitatea de a detecta și a distinge pietonii de alte ținte adiacente mai mari sporește suplimentar cerințele legate de rezoluția în azimut a senzorului. Identificarea rapidă și sigură a tunelurilor, a podurilor sau stabilirea înălțimii obstacolelor aflate pe carosabil sunt scenarii care implică o precizie foarte bună de măsurare a unghiului de elevație.

Producătorii de echipamente radar obțin aceste performanțe utilizând tehnici bazate pe sisteme cu intrări și ieșiri multiple (multiple input multiple output, MIMO). Astfel, un senzor echipat cu un număr de N antene fizice de transmisie și M antene fizice de recepție se comportă ca și un sistem cu $N \times M$ antene virtuale de recepție. Avantajul acestei metode este că menține costurile relativ reduse ale întregului sistem, îmbunătățind însă semnificativ rezoluțiile unghiulare și reducând în același timp numărul de impulsuri transmise de către radar. Limitarea impulsurilor semnalului transmis înseamnă un timp de scanare mai scurt și elimină concomitent anumite efecte negative produse de latența senzorilor, cum ar fi de exemplu timpul de recunoaștere a țintelor noi.

„Range walk” este un efect în care o țintă în mișcare își schimbă celula pozițională exact între impulsurile din trenul de impulsuri al unui semnal radar FMCW. El are ca rezultat atât inducerea de erori suplimentare în măsurarea vitezelor, cât și reducerea preciziei de detecție și de urmărire a obiectelor de interes. Aceste efecte negative pot fi evitate, generând semnale cu rate de variație mai rapidă a frecvenței. În schimb, creșterea acestei rate necesită o eșantionare și o conversie digitală mai rapidă a semnalului la receptor și în consecință circuite electronice mai complexe, deci mai scumpe. În plus, cresc și cerințele legate de viteza de acces la memoria RAM asociată procesorului numeric de semnal, de viteza de procesare a transformatei Fourier rapide (FFT) și de capacitatea de stocare a algoritmilor și a datelor în memoria de la bord.

Parametrii de operare impuși de către tehnica MIMO cu antene virtuale necesită un sistem de procesare extrem de performant, cu memorie RAM rapidă și cu capacități relativ mari, începând de la 4 până la 12MByte și capabilități specifice de procesare a semnalului radar, inclusiv acceleratoare hardware pentru calculul FFT.

Radarul are două blocuri funcționale majore (Figura 4). Unitatea analogică de radio-frecvență (sau frontend RF) conține antenele sistemului și gestionează atât generarea, transmiterea, recepția și condiționarea semnalului util cât și conversia analog-digitală și filtrarea semnalului recepționat. Pe de altă parte, unitatea digitală de calcul (sau microcontrolerul radar) transformă semnalul de recepție preprocesat

din domeniul timp în domeniul frecvență, identifică ținte, calculează distanța până la țintă, viteza relativă radială și unghiul către obiectul de interes. În plus, aceasta realizează funcțiile avansate ale sistemului, cum ar fi clasificarea și urmărirea sau funcțiile care controlează elementele active ale vehiculului: motorul, frâna și sistemul de direcție.




Figura 4: Schema bloc a unui sistem radar

Fiecare modalitate suplimentară de luare automată a deciziilor, legate de dinamica mașinii (Figura 5) crește efortul computațional necesar. Acesta crește suplimentar pe măsură ce standardele internaționale de siguranță a autoturismelor impun funcții avansate cu implementări din ce în ce mai performante ale senzorilor radar. De exemplu, programul de verificare a autoturismelor noi NCAP (New Car Assessment Programme) specifică necesitatea și parametrii de operare a funcțiilor de siguranță bazate pe sisteme radar, cum ar fi frânarea automată de urgență în intersecții sau detectarea și protecția pietonilor aflați în spatele altor mașini, având intenția de a traversa carosabilul.

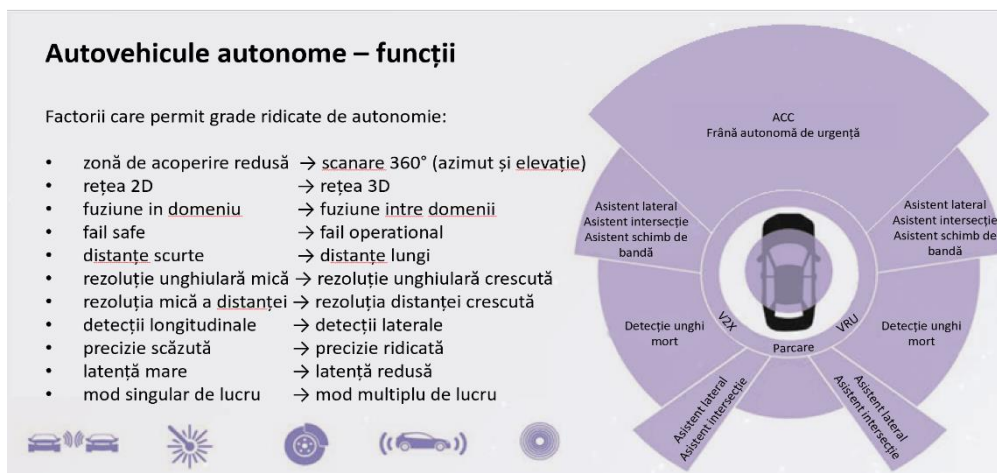


Figura 5: Funcții necesare pentru vehiculele autonome

Din punctul de vedere al procesării de semnal, importanța în continuă creștere pe care o are siguranța funcțională a sistemelor radar a transformat microcontrolerele

specifice prelucrării digitale a semnalelor radar în diferențiatori arhitecturali cheie între ofertele concurente, disponibile pe piață. Producătorii de automobile și furnizorii de echipamente electronice sunt conștienți de aceste diferențe și utilizează în consecință puterea de calcul a radarului într-un mod cât se poate de eficient, optimizând astfel performanțele sistemelor avansate de asistență a șoferilor (Advanced Driver Assistance Systems, ADAS) și oferind siguranță majoră atât șoferului cât și pasagerilor.

Eficiența energetică este o considerație critică pentru orice aplicație radar îmbarcată în autoturisme. Indiferent dacă vehiculul este alimentat cu combustibil lichid, electricitate sau hibrid, gestionarea consumului de energie și a modului de disipare termică sunt deosebit de importante, în special pentru mașinile cu mai mulți transmițători radar, datorită puterilor RF relativ mari corelate cu posibilitățile limitate de cuplaj și disipare termică. Disiparea energiei și managementul termic se agravează atunci când rețelele de senzori de la bordul vehiculelor devin și mai dense, oferind puține prize de flux de aer și răcire.

2 SISTEME RADAR

2.1 Tipuri de radare în autovehicule

Un sistem radar poate transmite și recepționa simultan unde electromagnetice în benzi de frecvență cuprinse între 3MHz și 300GHz, fiind conceput să extragă din semnalul reflectat de un obiect - țintă informații utile pentru identificarea și clasificarea obiectului respectiv. Parametrii de interes sunt: distanța relativă, viteza relativă, poziția unghiulară în elevație și azimut și radar cross section (RCS).

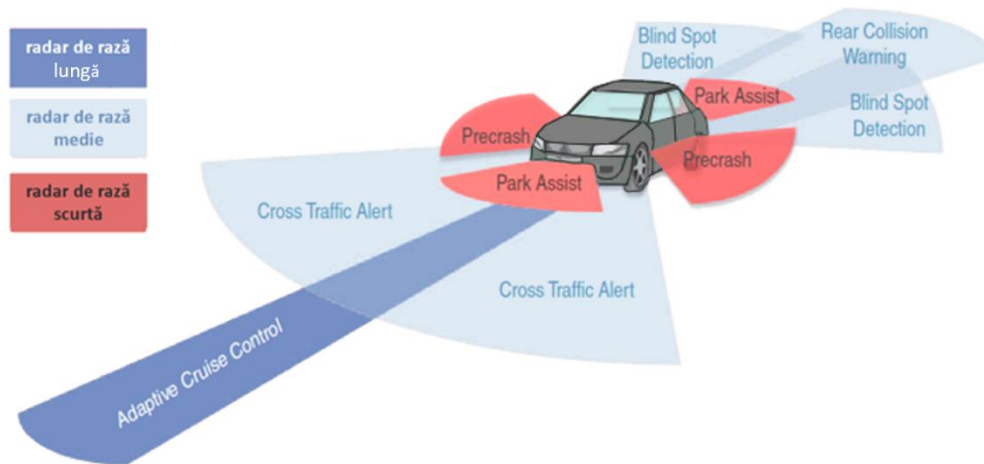


Figura 6: Tipuri de radare în autovehicule

Raza de acțiune a radarelor în autovehicule variază în funcție de tipul sistemului (tehnologie transceiver, forma semnalului transmis, layout de antenă) și de condițiile exterioare (temperatură, umiditate, gradul de reflexie al șoselei, etc.), între câțiva centimetri, pentru funcția de parcare asistată (Park Assist), aproximativ 70m pentru funcția de alertă de trafic încrucișat (Front Crossing Traffic Alert) și peste 250m pentru funcția de control adaptiv al vitezei de croazieră (Adaptive Cruise Control). Unghiul de azimut acoperit depinde în principal de tipul radarului, având valori tipice de +/- 15° pentru radarul cu rază lungă de acțiune (long range radar, LRR), +/- 45° pentru radarul cu rază medie de acțiune (medium range radar, MRR) și +/- 90° pentru radar cu rază scurtă de acțiune (short range radar, SRR).

Funcțiile realizate de cele trei tipuri de radare reprezentate în Figura 6 sunt:

- ACC: Adaptive Cruise Control, rază lungă de acțiune
- AEB: Autonomous Emergency Brake, rază medie de acțiune
- RCTB: Rear Crossing Traffic Alert with Brake, rază medie de acțiune
- FCTA: Front Crossing Traffic Alert, rază medie de acțiune

- BSD: Blind Spot detection, rază medie de acțiune
- LCA: Lateral Collision Avoidance, rază scurtă de acțiune
- PA: Park Assist, rază scurtă de acțiune

2.2 Distanța senzor – țintă

Determinarea distanței R pînă la obiectul – țintă este o funcție fundamentală a oricărui senzor radar și are la bază măsurarea timpului necesar τ al unui impuls electromagnetic transmis pentru a parcurge drumul dus – întors între antena de transmisie și antena de recepție, impulsul fiind reflectat de obiectul - țintă. Având în vedere că viteza de propagare a impulsului electromagnetic în atmosferă este aproximativ egală cu viteza luminii $c = 3 \times 10^8 \frac{m}{s}$, obținem

$$R = \frac{c\tau}{2} \tag{2.1}$$

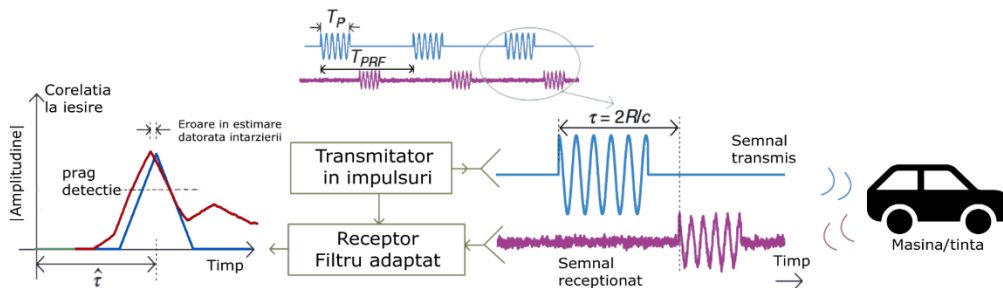


Figura 7: Principiul de măsurare a distanței până la obiectul – țintă

Forma și durata semnalului transmis stabilesc performanța senzorului și distanța maximă acoperită. Perioada impulsului electromagnetic T_{PRF} limitează distanța maximă deoarece într-o perioadă, impulsul transmis trebuie să aibă timp să parcurgă drumul dus – întors între sursă și cea mai îndepărtată țintă. Durata unui impuls T_p din unda continuă transmisă trebuie aleasă astfel încât să permită o rezoluție de detecție cât mai bună. Rezoluția înseamnă capacitatea senzorului de a diferenția două obiecte diferite aflate însă în apropiere. Cu cât T_p este mai mic, cu atât rezoluția este mai bună. Pe de altă parte însă, durata scurtă a unui impuls transmis reduce energia acestuia și limitează în consecință raportul semnal / zgomot (SNR, signal-to-noise ratio) respectiv gradul de performanță al sistemului.

Semnalul transmis $s(t)$ este atenuat datorită pierderilor în cele două căi de transmisie și a reflexiei imperfecte la nivelul obiectului – țintă. La recepție intervin în plus zgomotul termic intern al echipamentului electronic, interferențele cu semnale reflectate de către alte obiecte și alte perturbații datorate factorului uman. Astfel, semnalul recepționat după demodulare, adică după eliminarea semnalului purtător de înaltă frecvență 77GHz și “mutarea” semnalului util în banda de bază, are forma următoare:

$$x(t) = as(t - \tau) + w(t) \tag{2.2}$$

- α este un scalar complex care redă atenuarea datorată factorilor de amplificare ale antenelor de transmisie respectiv de recepție, pierderile în căile de transmisie și radar cross section (RCS) a obiectului urmărit, iar
- $w(t)$ este zgomotul alb gaussian, cu medie nulă și varianță σ^2 .

Cum am arătat mai sus, determinarea distanței între sursă și țintă este echivalentă cu determinarea timpului de întârziere τ , având în vedere că forma semnalului transmis $s(t)$ este cunoscută cu exactitate. Filtrul ideal de recepție calculează gradul de corelație între semnalul transmis și cel reflectat, ajuns la receptor:

$$y(\tau) = \int x(t) s^*(t - \tau) dt \quad (2.3)$$

Estimatorul optim al timpului de întârziere τ este reprezentat de valoarea maximă a gradului de corelație $y(\tau)$, calculat de către receptor.

2.3 Viteza relativă între radar și obiectul – țintă

Estimarea vitezei relative a unui obiect față de sistemul de referință se face utilizând efectul Doppler, care se manifestă prin modificarea frecvenței unui semnal transmis. Semnalul reflectat de către ținta aflată în mișcare are la recepție o variație în frecvență direct proporțională cu viteza relativă dintre radar și țintă. Modificarea frecvenței se datorează "comprimării" respectiv "dilatării" undei electromagnetice în spațiul dintre radar și țintă, așa cum este arătat în figura de mai jos.




Figura 8: Variația frecvenței, datorată vitezei relative între radar și țintă

Variația este pozitivă, deci frecvența la receptor crește, atunci când ținta se apropie de sistemul de referință, deci de radar. Atunci când ținta, de exemplu un avion sau un autoturism, se depărtează de radar, atunci variația Doppler a frecvenței este negativă, la receptor fiind vizibilă o scădere a frecvenței semnalului reflectat. Variația frecvenței Doppler este invers proporțională cu lungimea de undă λ a semnalului purtător:

$$f_d = \pm \frac{2v}{\lambda} \quad (2.4)$$

Lungimea de undă a unui radar de 77GHz este de

$$\lambda_{77GHz} = \frac{c}{f} = \frac{3 \times 10^8 \frac{m}{s}}{77 \times 10^9 s^{-1}} = 3,9 \text{ mm} \quad (2.5)$$

Pentru ca un sistem radar să permită determinarea simultană a vitezei relative și a distanței până la obiectul, respectiv până la obiectele relevante, semnalul continuu transmis trebuie modulată în frecvență. Un astfel de sistem radar poartă denumirea FMCW (frequency modulated continuous wave).




Figura 9: Semnal transmis și recepționat de un radar FMCW

Semnalul transmis (roșu) constă dintr-o serie de impulsuri (*chirps*) ale căror frecvență variază liniar în timp, de la f_1 la f_2 . Notând constanta de liniaritate cu $K = \frac{f_2 - f_1}{T}$, unde T reprezintă durata unui chirp și T_0 reprezintă perioada de repetiție a chirpurilor (PRF, *pulse repetition frequency*) și considerând frecvența semnalului purtător f_c , putem scrie ecuația semnalului transmis după cum urmează:

$$s(t) = \exp[j2\pi(f_c + 0,5Kt)t], \text{ pentru } 0 \leq t \leq T \quad (2.6)$$

Cum am arătat mai sus, semnalul reflectat și recepționat (violet) este corelat cu semnalul transmis, obținându-se astfel distanța până la țintă. Această operație este repetată de P ori, P indicând numărul de impulsuri (*chirps*) dintr-un tren de impulsuri (vezi semnalul roșu din Figura 10).

În radarele îmbarcate în autovehicule moderne $P = 128$ sau 256 . Un ciclu radar (Figura 10) are o perioadă tipică de 40ms, permițând astfel 25 de "imagini" pe secundă. El este împărțit în două: *perioada de achiziție*, în care transceiverul radar emite și recepționează concomitent unde electromagnetice și *perioada de procesare de semnal*, timp în care microprocesorul sistemului realizează atât prelucrarea de bază a semnalului recepționat (adică determinarea distanței, vitezei relative și a poziției unghiulare pentru fiecare obiect în parte) cât și clasificarea și urmărirea traiectoriilor obiectelor de interes.




Figura 10: Tren de impulsuri în semnalul de transmisie

Reprezentarea 2D a semnalului recepționat din Figura 11 consideră două axe de timp, un index lent p , reprezentând numărul de impulsuri dintr-un tren de impulsuri și un index rapid n , reprezentând numărul de eșantioane preluate la recepție din semnalul de corelare corespunzător fiecărui impuls (chirp) în parte. Frecvența de eșantionare f_s (cu valori tipice de 10 – 80 MHz în banda de bază) permite preluarea a N eșantioane în fiecare impuls de durată T . Notând cu R distanța până la obiectul țintă și cu T_0 perioada trenului de impulsuri, semnalul eșantionat la receptor va avea următoarea formă [7]:

$$d(n, p) \approx \exp\left\{j2\pi\left[\left(\frac{2KR}{c} + f_d\right)\frac{n}{f_s} + f_d p T_0 + \frac{2f_c R}{c}\right]\right\} + \omega(n, p) \quad (2.7)$$




Figura 11: Analiza semnalului radar la receptor

Aplicând o primă transformată Fourier rapidă (FFT) asupra eșantioanelor $[0, N - 1]$ din primul impuls, deci analizând spectrul de frecvență al acestuia, obținem frecvența $f_b = \frac{2KR}{c}$ cuplată cu frecvența Doppler f_d . Deoarece frecvența Doppler este mult mai mică (de regulă cu câteva ordine de mărime) decât frecvența semnalului purtător f_c , este nevoie de zeci sau sute de ecouri corespunzătoare câte unui impuls pentru a putea calcula cu precizie variația Doppler. Astfel, o a doua transformată Fourier discretă este aplicată pe întregul tren de impulsuri coerente, deci pe axa P a reprezentării 2D a semnalului recepționat. Rezultatul transformatei permite calculul frecvenței Doppler și în consecință a vitezei radiale relative între radar și obiectul – țintă.

Radarele automotive moderne procesează simultan mai multe canale de recepție (în exemplul din Figura 12 sunt patru canale Rx). Așa numitele radare *monopuls 3D* [8] au antena de recepție grupată în patru subgrupe, permițând determinarea pozițiilor unghiulare ale țintelor pe baza analizei următoarelor trei semnale recepționate: semnalul sumă, semnalul diferență în azimut și semnalul diferență în elevație. Cele trei semnale au canale de recepție dedicate și sunt procesate simultan. Al patrulea canal de recepție este folosit pentru canalul auxiliar Ω . În plus față de reprezentarea 2D a semnalului recepționat putem considera o a treia axă dată de numărul de canale de recepție, obținând astfel cubul de date din Figura 12.




Figura 12: Cubul de date al unui radar automotive

2.4 Poziția unghiulară a unui obiect – țintă

În Figura 13 observăm o situație frecvent întâlnită în trafic, cu mai multe ținte, unele mobile iar altele staționare, reflectând semnalele transmise de către radar pe cale directă dar și indirect, de exemplu prin reflexia datorată șoselei. Într-o astfel de situație, distanța până la cele două autovehicule este aproximativ egală, pentru diferențierea țintelor fiind necesară determinarea corectă a pozițiilor unghiulare ale celor două obiecte.

Din punctul de vedere al unui radar automotive, un obiect – țintă este descris într-un sistem de coordonate sferice (R, ϕ, φ) , unde ϕ reprezintă unghiul de azimut și φ reprezintă unghiul de elevație. Cum am prezentat mai sus, fiecărui obiect îi este atribuită o viteză relativă v .

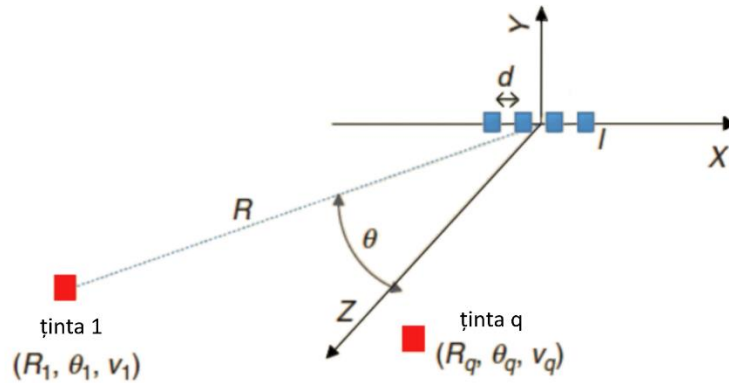


Figura 13: Poziția unghiulară a obiectelor

Pentru simplificare considerăm problema determinării poziției unghiulare în cazul 2D, deci exclusiv a unghiului de azimut. Pentru a putea determina unghiul de azimut ϕ corespunzător fiecărei ținte este necesară o informație deci o dimensiune suplimentară a semnalului recepționat. Aceasta se poate obține utilizând un grup de antene de recepție aranjate linear în planul $z = 0$, aflate la o depărtare constantă d între ele (vezi Figura 13). Considerând obiectul - țintă cu indicele q , timpul de întârziere văzut de către fiecare antenă cu indicele l din grup va fi diferit și egal cu:

$$\tau_{lq} = \frac{2(R_q + v_q t) + ld \sin \theta_q}{c} \quad (2.8)$$

Întârzierile diferite detectabile la antenele corespunzătoare grupului de antene produc o variație progresivă și caracteristică a fazelor semnalelor recepționate de către fiecare antenă în parte, permițând astfel determinarea unghiului de azimut ϕ_q .

Pentru localizarea tridimensională a obiectelor - țintă, deci stabilirea atât a unghiului de azimut cât și a unghiului de elevație, radarele automotive moderne au un layout mai complex al elementelor constitutive din grupul de antene de transmisie (vezi antena unui radar cu rază lungă de acțiune din Figura 14).

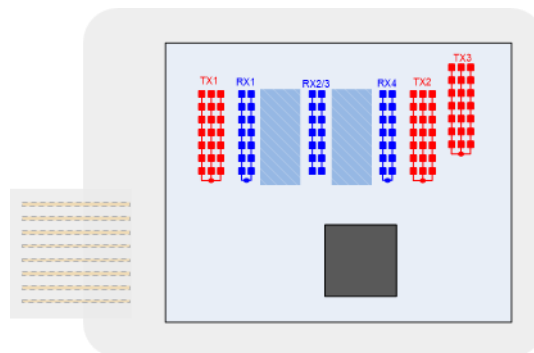


Figura 14: Exemplu de layout al elementelor antenelor în radare automotive

2.5 Radarul cu undă continuă modulată în frecvență (FMCW)

Radarul cu undă continuă modulată în frecvență (FMCW) este utilizat de regulă în aplicațiile automotivă și permite determinarea simultană atât a distanțelor, cât și a vitezelor relative ale țintelor de interes. Rezoluția în determinarea distanței este invers proporțională cu lățimea de bandă a semnalului FMCW. Cu cât lățimea de bandă crește, deci $f_2 - f_1$ crește (vezi Figura 9), cu atât rezoluția distanței scade, deci este mai bună, permițând separarea țintelor aflate la distanțe mai mici între ele. Rezoluția Doppler depinde de durata unui impuls și de numărul de impulsuri într-un interval de procesare coerentă (în engleză, coherent processing interval, CPI).

Alegerea formei de undă a semnalului radar este decisivă pentru performanța unei aplicații și trebuie făcută luând în considerare posibilitățile tehnologice actuale și cerințele crescute legate de urmărirea țintelor multiple și de rezoluțiile cât mai bune pentru determinarea distanței, a vitezei relative și a pozițiilor unghiulare ale obiectelor de interes.

Una dintre problemele cheie ale radarelor FMCW este liniaritatea semnalelor modulate în frecvență [9]. Neliniaritatea în frecvență ($S = \frac{df}{dt}$) a semnalului transmis FMCW (și în consecință și a celui recepționat) influențează direct frecvența f_b care indică distanța până la țintă, scăzând astfel performanța radarului în precizia de detecție a distanțelor. Pentru a asigura un grad de liniaritate maxim în banda de frecvență utilizată în radarele FMCW (de regulă 250 MHz până la 1 GHz) se folosesc componente analogice în circuitul pe linia de transmisie cu variație foarte redusă datorită tensiunii de alimentare sau a temperaturii de operare. De exemplu oscilatorul controlat în tensiune, VCO (în engleză voltage controlled oscillator), "inima" oricărui radar, și convertorul digital – analogic de la ieșire sunt concepute în așa fel, încât dependența acestora de temperatură și de tensiunea de operare să fie foarte reduse. Metode uzuale aplicate sunt folosirea buclor PLL (phase locked loops) în generarea frecvențelor și a tabelor de lookup pentru corecția deviațiilor de la valorile nominale.




Figura 15: Efectul neliniarității în frecvență a semnalului FMCW

În plus față de neliniaritatea în frecvență, parametrii cheie care caracterizează performanța unui sistem radar sunt puterea de transmisie (valori tipice între 10 - 13 dBm), zgomotul (jitterul) de fază, cu valori tipice de 12 - 14 dB și puterea consumată (tipic 3 - 4 W).

2.6 Efectul micro – Doppler

Efectul Doppler prezentat în subcapitolul 2.3 nu permite detecția în situații reale a unor obiecte vulnerabile și de dimensiuni reduse, cum ar fi de exemplu pietoni sau bicicliști. Într-un scenariu simplu, în care o mașină circulă cu viteză constantă pe o șosea iar o altă mașină este parcată regulamentar pe marginea carosabilului, considerăm un pieton ascuns după mașina parcată, având intenția de a traversa strada (vezi Figura 16.a). Analizând în mod tradițional diagrama distanță - Doppler, pietonul ascuns în spatele mașinii parcate nu poate fi detectat [10]. În consecință, este necesar un alt tip de analiză a semnalului eco recepționat.

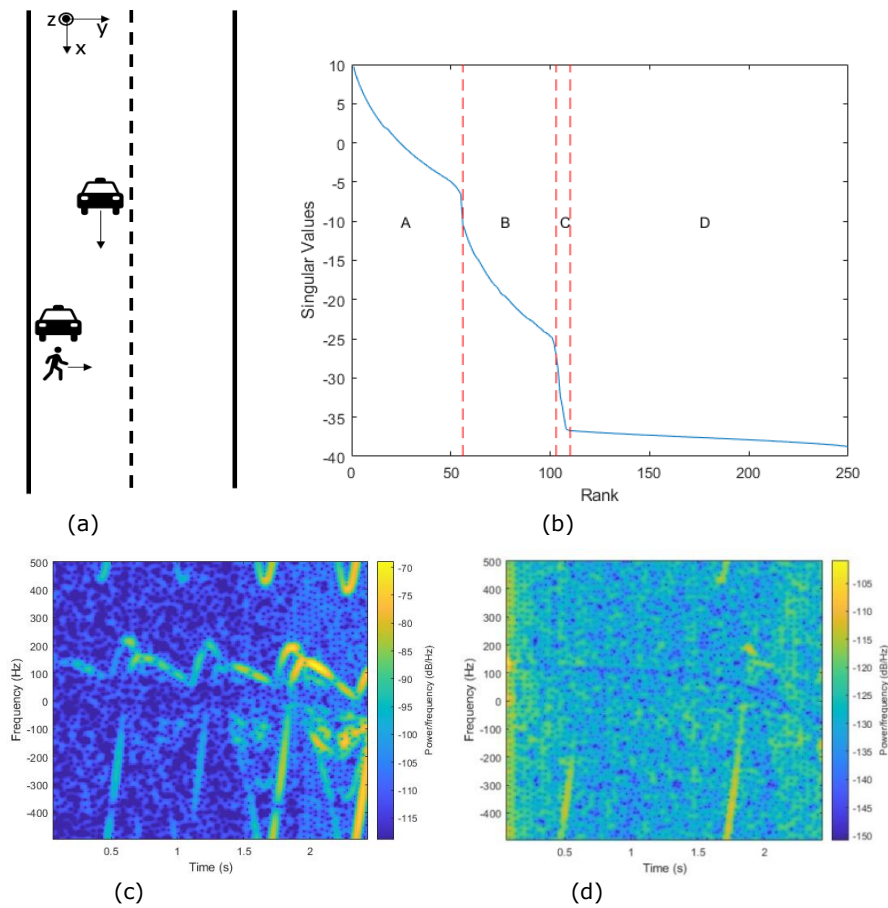


Figura 16: Efectul micro – Doppler, cauzat de un pieton

Semnalele radar reflectate de către pietoni conțin o amprentă biometrică datorată bătăilor inimii, mișcării vaselor sanguine și a altor micro-mișcări ale pielii cauzate de respirație și puls. Ambele procese, respirația, respectiv bătăile inimii, sunt periodice cu frecvențe între 0,2 - 0,5 Hz respectiv 0,8 - 5 Hz [11].

În spectrograma din Figura 16.c care redă spectrul semnalului reflectat de către pieton într-o perioadă de 2,5 secunde, se observă multiple curbe parabolice provocate de mișcările mâinilor și picioarelor pietonului. Din păcate, acest semnal nu este disponibil la receptor ci este prezentat pentru vizualizare. Spectrograma întregului semnal recepționat, generat de ambele obiecte din zona de acoperire a radarului, este în continuare dominată de către ecoul radar cauzat de mașina parcată. Pentru a putea extrage semnalul datorat pietonului, se aplică descompunerea în valori singulare (parametrii "s") [10], [12]. Metoda permite extragerea componentelor principale din semnalul radar recepționat. În Figura 16.b se pot distinge patru regiuni diferite A, B, C și D, corespunzând contribuției mașinii parcate, a ambelor obiecte din zona de acoperire, a pietonului și respectiv a zgomotului rezidual. Reconstrucția semnalului micro-Doppler de interes se realizează pe baza valorilor singulare exclusiv din regiunea C, aplicând ecuația:

$$x_{Dr} = U_{x_D} S_{x_D} V_{x_D}^T \quad (2.9)$$

unde U_{x_D} și V_{x_D} sunt vectorii singulari, iar S_{x_D} sunt valorile singulare selectate din regiunea C. Spectrograma lui x_{Dr} din Figura 16.d evidențiază prezența pietonului și permite funcției de frânare autonomă de urgență AEB să intervină corespunzător.

3 TEHNICI DE PROCESARE A SEMNALELOR RADAR

Sistemele radar folosesc o varietate de metode de procesare a semnalului pentru a putea extrage informații utile din ecoul radar, ca de exemplu: detecția țintelor în mișcare, integrarea semnalului pentru a îmbunătăți raportul semnal-pe-zgomot, compresia impulsului pentru îmbunătățirea rezoluției și metode de estimare a unghiului și timpului de întârziere pentru urmărirea în timp a pozițiilor radiale și unghiulare a țintelor. Primele radare au folosit procesoare și tehnici analogice pentru implementarea acestor funcții. Ulterior, posibilitatea de a implementa algoritmi mult mai performanți, susținută de îmbunătățirile exponențiale ale vitezei și capacității de calcul a procesorului digital au determinat introducerea acestuia în practic toate sistemele radar moderne.

În timp ce principiile fundamentale ale prelucrării digitale de semnal provin din domeniile audio și video, unele particularități ale radarelor nu apar în cazul procesării semnalelor audio sau video. Una dintre diferențele majore este că semnalele radar, atunci când sunt detectate de un receptor coerent (în fază / în cuadratură) sunt complexe, spre deosebire de semnalele audio sau imagini, care sunt reale. În consecință, procesoarele digitale trebuie să ofere mecanisme de aritmetică pentru semnale complexe, concomitent cu o capacitate dublă de stocare pentru fiecare eșantion. O altă diferență importantă este că semnalele audio și video sunt prezente în banda de bază, adică nu au semnal purtător. Semnalele radar sunt modulate pe o frecvență purtătoare înainte de transmisie și trebuie demodulate la receptor (vezi Figura 19). Acest fapt necesită o atenție deosebită în aplicarea teoremei eșantionării, dar permite în același timp aplicarea metodelor de procesare digitală a frecvențelor intermediare (IF). De asemenea, semnalele radar prezintă game dinamice extrem de ridicate. Gama dinamică a semnalului recepționat este de regulă de ordinul de mărime de 60 până la 80 dB. Banda largă a semnalelor radar necesită o rată de eșantionare ridicată, acest lucru însemnând că un număr mare de valori de date eșantionate, deseori miliarde pe secundă, trebuie procesate în timp real. Procesoarele de radar folosesc des filtre cu transformată Fourier rapidă (FFT) și filtre cu răspuns finit la impuls (FIR). În sfârșit, semnalele radar la receptor au deseori valori foarte scăzute ale raportului semnal-pe-zgomot, sub 0 dB pentru ecurile brute înainte de efectuarea oricărei prelucrări.

3.1 Bazele prelucrării numerice a semnalelor radar

Pentru a putea fi prelucrat numeric, semnalul real trebuie eșantionat și cuantizat. Eșantionarea reprezintă discretizarea în timp a unui semnal continuu. Rezultatul eșantionării unui semnal continuu $x(t)$ este un șir de eșantioane. Cuantizarea semnalului înseamnă discretizarea în amplitudine a eșantioanelor, proces care generează implicit o eroare sistematică, numită zgomot de cuantizare. Ca și rezultat se obține un semnal $x[n]$ format din N eșantioane, fiecare având valori cuantizate.

Transformata Fourier discretă (DFT), deci reprezentarea finită în domeniul frecvență a semnalului analizat, este calculată cu formula:

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-j\frac{2\pi}{N}kn}, \quad k = 0, \dots, N-1 \quad (3.1)$$

Un rol deosebit de important în procesarea semnalelor radar îl are transformata Fourier discretă a semnalului sinusoidal complex:

$$x[n] = A e^{j\frac{2\pi}{N}k_0 n}, \quad n = 0, \dots, N-1 \quad (3.2)$$

Pentru calculul unei singure valori a transformatei Fourier discrete sunt necesare N operații de înmulțire și acumulare, prin urmare calculul spectrului complet de frecvență are o complexitate de procesare proporțională cu N^2 .

O proprietate importantă a transformatei Fourier este faptul că eșantionarea într-un domeniu determină o replicare periodică a semnalului în domeniul complementar. Astfel, eșantionarea semnalului în domeniul timp cu o frecvență Nyquist, corespunzătoare teoremei eșantionării, deci mai mare decât lățimea de bandă B a semnalului, conduce la multiplicarea în domeniul frecvență a spectrului semnalului inițial (vezi Figura 17).




Figura 17: Spectrului multiplicat al unui semnal complex eșantionat

Majoritatea procesoarelor digitale folosesc frecvența de eșantionare Nyquist în contextul semnalelor reale cu spectru de frecvență în banda de bază. Semnalele radar coerente însă sunt modulate pe o frecvență de purtător, având spectrul necentrat la 0 Hz, iar eșantioanele în fază (I), respectiv în cuadratură (Q) ale semnalului recepționat sunt combinate într-un semnal complex. Cu toate acestea, teorema lui Nyquist încă se aplică, pentru că nimic în derivarea sa nu se bazează pe faptul că semnalul care este evaluat este un semnal real sau are un spectru în banda de bază. Dacă semnalul analizat este unul complex, atunci și eșantioanele prelevate la frecvențe B eșantioane / sec sau mai rapid vor fi de asemenea evaluate complex.

Deși eșantionarea semnalului radar ar putea fi făcută teoretic încă în situația semnalului modulat pe purtător (de frecvență f_0), limitările tehnologice aduse de procesarea semnalelor de înaltă frecvență (f_0 are ordinul de mărime de zeci de GHz) conduc la necesitatea de a aduce forma și energia semnalului de interes în banda de bază folosind un receptor coerent, având schema bloc din Figura 18. Cele două semnale de la ieșirea receptorului sunt semnale reale în banda de bază ($-B/2, B/2$) și pot fi eșantionate cu o frecvență ($f_s > B$) (f_s are ordinul de mărime de zeci de MHz).




Figura 18: Prelucrarea la receptor a semnalului radar cu valori complexe

Schema bloc din Figura 18 implică unele cerințe greu de implementat în realitate. De exemplu, cele două oscilatoare de referință $2\cos(2\pi f_0 t)$, respectiv $2\sin(2\pi f_0 t)$ trebuie să aibă un defazaj de exact 90° , în timp ce amplificarea și întârzierea pentru fiecare din cele două canale de ieșire trebuie să fie identice în întreaga bandă de frecvență a semnalului. În cazul sistemelor de frecvență înaltă acest lucru este dificil de realizat cu precizie adecvată. În realitate, receptoarele radar utilizează o frecvență intermediară (IF) aflată între frecvența semnalului purtător și cea din banda de bază, care este utilizată pentru o demodulare parțială, cu hardware analogic. Eșantionarea în timp este realizată încă pe purtătorul IF, conversia în bandă de bază urmând a fi procesată digital.

Nivelul de zgomot asociat receptorului este calculat ca și raportul dintre puterea zgomotului la ieșirea receptorului și puterea acestuia la intrare, ponderat cu inversul factorului de amplificare G :

$$F = \frac{1}{G} \frac{N_{out}}{N_{in}} \quad (3.3)$$

Multiplexorul din Figura 19 este contributorul net major la nivelul total de zgomot termic. Efectul produs de zgomotul multiplexorului în lanțul de prelucrare este însă redus de amplificarea datorată primei trepte (low noise amplifier, LNA). Contribuția primei trepte de prelucrare predomină astfel în nivelul total de zgomot.

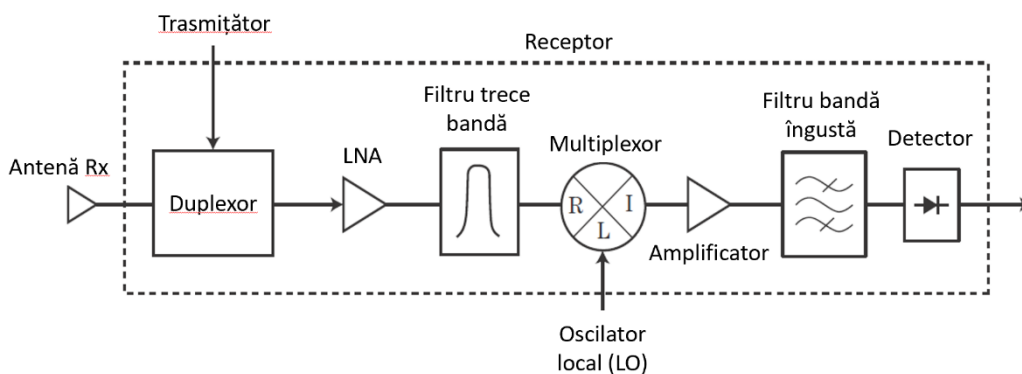


Figura 19: Schema bloc a unui receptor radar

3.2 Procesorul de semnal radar

Procesorul numeric de semnal este componenta unui sistem radar care permite extragerea informațiilor esențiale legate de mediul înconjurător, de exemplu numărul de ținte urmărite sau nivelul de perturbare, din semnalele brute de recepție. Procesorul de semnal este compus din două elemente de bază: un set de algoritmi care prelucrează datele radar și dispozitivul hardware pe care rulează acești algoritmi.

Figura 20 prezintă schema bloc a unui procesor modern de semnal radar dezvoltat de către liderul mondial în circuite integrate radar pentru automobile, NXP Semiconductors. În partea de sus a figurii se observă categoriile de algoritmi de procesare, iar în partea de jos se observă subcomponentele hardware alocate fiecărei etape de procesare software. Recepția și condiționarea semnalului recepționat au loc în mod tradițional în unitatea analogică de radio-frecvență. Generația următoare de circuite integrate urmărește integrarea celor două blocuri din Figura 4, frontend-ul RF și procesorul numeric de semnal, într-un singur chip monolitic. Semnalul brut de recepție este eșantionat în banda de bază cu frecvențe dependente de lățimea de bandă a acestuia, de regulă între 10 și 80 de MHz. Astfel, la intrarea procesorului apare un flux digital de date care trebuie procesat foarte rapid, în timp real. Operațiile de calcul efectuate în prima fază sunt operații fixe, în special transformate Fourier rapide (FFT) în cascadă pentru calculul distanței, frecvenței Doppler și respectiv a direcției de sosire (DOA) a ecoului radar. Pentru accelerarea execuției operațiilor din faza de procesare a semnalului brut, procesorul numeric de semnal conține un accelerator hardware (SPT) dedicat funcțiilor FFT, care poate fi utilizat flexibil, în funcție de necesitățile fiecărei aplicații, prin intermediul unui nucleu programabil DSP. Nucleul Cortex M7 are rolul de a configura și controla semnalul transmis Tx, de exemplu prin transmisia cu faze diferite a semnalului Tx prin mai multe antene situate la distanțe cunoscute. Această metodă de beamforming [13] permite direcționarea unghiulară a frontului semnalului electromagnetic transmis.

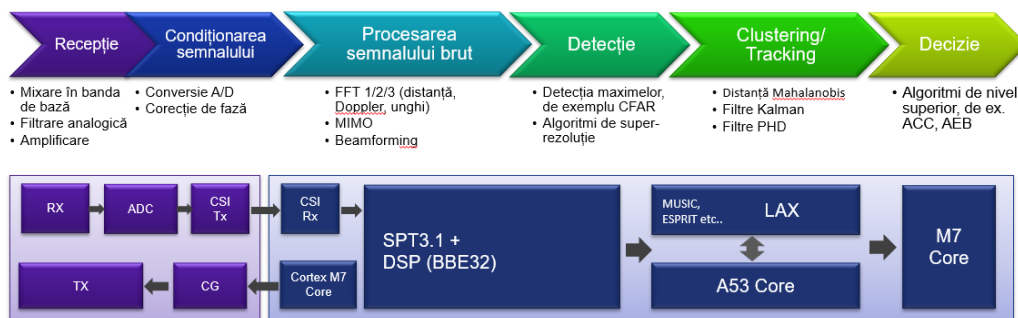


Figura 20: Procesorul de semnal radar S32R45, sursă NXP

În etapa de detecție, pentru fiecare celulă din zona de acoperire a sensorului, se calculează intensitatea semnalului recepționat și viteza relativă asociată obiectului situat în celula respectivă. Scopul primar al acestei etape de procesare este extragerea semnalului util din semnalul recepționat atenuat, perturbat și afectat de zgomot. Algoritmii utilizați urmăresc detecția valorilor maxime, de exemplu prin metoda CFAR (a se vedea subcapitolul 3.3) și îmbunătățirea rezoluției de localizare și viteză, cum ar fi MUSIC [14] sau ESPRIT [15]. Operațiile de calcul sunt operații de

algebră liniară, de exemplu transpuneri și înmulțiri de matrici sau calculul inverselor și al valorilor singulare ale unor matrici. Și în această fază de procesare, acceleratoarele hardware dedicate de tipul LAX (Figura 20) permit factori de accelerare de peste 50 de ori față de procesarea prin nuclee programabile clasice. Deoarece vitezele de calcul necesare pentru efectuarea acestor operații repetitive sunt foarte ridicate, unele sisteme radar folosesc nuclee cu reprezentare cu virgulă fixă a numerelor, permițând astfel o implementare eficientă în ceea ce privește aria activă a procesorului. În cazul sistemelor destinate aplicațiilor mai puțin performante, ca de exemplu radarele de detecție a unghiului mort, nucleele selectate pentru procesarea semnalului brut și pentru rularea algoritmilor de detecție folosesc reprezentarea cu virgulă mobilă a numerelor, oferind astfel o precizie aritmetică mai bună și o gamă mai largă de valori. Capacitatea computațională necesară în acest caz se situează între 2 și 20 de GFLOPS (miliarde de operații cu virgulă mobilă pe secundă).

În etapa de clustering și tracking, deci de grupare a ecourilor detectate în structuri compacte corespunzătoare obiectelor de interes și de urmărire a acestora, nuclee de procesare trebuie să aibă o latență de acces la memoriile de date foarte redusă (Figura 21). Nucleele cu arhitectură ARM A53 sau R52 oferă capacitatea de calcul necesară între 3 și 10 DMIPS (milioane de operații Dhrystone pe secundă), cu câteva ordine de mărime mai scăzută decât cea necesară în primele două etape.

Etapa de decizie este caracterizată de un nivel de siguranță funcțională extrem de ridicată, de regulă ASIL-D. Rezultatul algoritmilor constă în comenzi critice ale componentelor active ale autoturismului: sistemul de ghidaj, motorul și sistemul de control electronic al frânelor. Dacă decizia propriu-zisă sau transmisia acesteia pe magistrala de date CAN ori Ethernet ar fi eronată sau întârziată, atunci viața șoferului și a celorlalți participanți la trafic ar fi pusă în pericol. Nucleele ARM M7 destinate execuției algoritmilor de nivel superior, ca de exemplu funcția de control adaptiv al vitezei de croazieră (Adaptive Cruise Control), rulează în modul lockstep, în care două nuclee rulează în paralel fiecare instrucțiune de cod, iar rezultatul operațiilor este comparat prin circuite hardware, la fiecare tact de operare. Implementarea acestei arhitecturi presupune două nuclee fizice cu redundanță în hardware, care oferă însă capacitatea de calcul netă corespunzătoare unui singur nucleu.

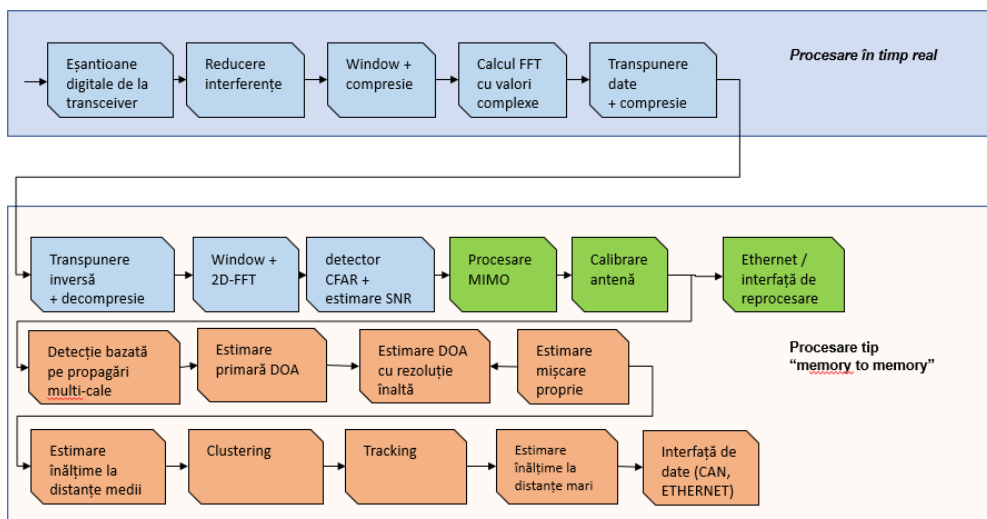


Figura 21: Schema funcțională a unui procesor numeric de semnal radar

Cu toate că etapele inițiale ale procesului de prelucrare a semnalului recepționat necesită viteze mari de calcul pentru procesarea în timp real (Figura 21), cerințele lor de stocare tind să fie relativ scăzute, cuprinse între 3 și 10 MB de memorie RAM. Acest lucru se datorează modului în flux a calculelor, care ia un bloc, respectiv un cub de date (Figura 12), îi aplică un filtru și transmite ulterior datele modificate mai departe către etapa următoare. Rezultatele intermediare nu se păstrează, astfel încât necesarul de memorie în fiecare fază a procesului este moderat.

Metricile procesorului de semnal se împart în două clase. Prima clasă descrie performanțele algoritmilor iar cea de-a doua descrie capabilitățile oferite de subcomponentele hardware. Cele mai importante metrici hardware sunt debitul de calcul și latența. Debitul de calcul reprezintă viteza netă de execuție cu care procesorul poate finaliza operații aritmetice. Acesta se măsoară în MFLOPS sau GFLOPS (miliarde de operații cu virgulă mobilă pe secundă). Majoritatea operațiilor executate în timp real (Figura 21) transformă un bloc de date de intrare de dimensiune fixă într-un alt bloc de date de ieșire, având de asemenea o dimensiune fixă. Timpul scurs între momentul în care primul element al blocului de intrare ajunge la un anumit nucleu și momentul în care primul element al blocului de ieșire este disponibil este denumit latența de execuție a operației. Metricile necesare pentru caracterizarea algoritmilor software de tracking sunt prezentate în detaliu în subcapitolele 5.1, 5.3 și 5.8.

O altă metrică importantă a procesorului numeric de semnal radar este mărimea memoriei RAM necesară pentru stocarea datelor de procesat, a rezultatelor intermediare și a coeficienților algoritmilor implementați, de exemplu coeficienții răspunsului la impuls în cazul filtrelor FIR. Algoritmii care lucrează cu un număr mare de eșantioane în blocul de date de intrare necesită evident memorii hardware de dimensiuni mai mari și duc la scăderea gradului de performanță a senzorului atunci când este necesară copierea datelor între memoriile locale, de exemplu între memoria cache de nivel 1 sau 2 (L1 / L2 cache) și memoria generală a sistemului (SRAM).

Deseori, funcția de transfer a unui filtru numeric poate fi implementată prin mai mulți algoritmi diferiți. Spre exemplu, o abordare simplificată a implementării unei transformate Fourier digitale cu N eșantioane în blocul de date de intrare necesită N^2 înmulțiri de valori complexe și încă N^2 adunări de valori complexe. În cazul uzual în care N este o putere a lui 2, algoritmul FFT Cooley-Tukey în baza 2 [16] necesită doar un număr de $(N/2) \log_2 N$ înmulțiri complexe. Complexitatea computațională și modul de implementare a unui anumit filtru au un efect direct asupra timpului de execuție și în consecință asupra mărimii și a costului de producție a procesorului de semnal. În plus, în procesoarele radar moderne, optimizarea transferului de date și organizarea ierarhică a diferitelor tipuri de memorii de date (cache pentru date, cache pentru instrucțiuni, RAM de sistem, etc.) este adesea mai importantă decât execuția cât mai rapidă a unui număr predefinit de instrucțiuni. Uneori cel mai bun algoritm nu este neapărat acela cu cele mai puține operații aritmetice.

În concluzie, sistemele radar conțin procesoare numerice de semnal cu o densitate foarte mare de tranzistori pe suprafața activă, de aproximativ un milion pe milimetru pătrat. Procesoarele combină circuite specifice cu viteză de calcul foarte rapidă care prelucrează semnalul brut în timp real, cu circuite cu latență redusă și acces ultra rapid la memoriile de date. În general, capacitatea de calcul necesară scade iar dimensiunea memoriei de date crește odată cu parcurgerea etapelor secvențiale de procesare a semnalului radar (Figura 21). Algoritmii PHD de urmărire a țintelor investigați în această teză sunt descriși în detaliu în capitolul 5. Aceștia sunt executați în a treia etapă de prelucrare a semnalului brut, iar pentru ei este esențial ca implementarea software să prezinte un grad de complexitate computațională cât mai scăzut.

3.3 Detecția bazată pe limita CFAR

Procesul de detecție a unei ținte începe prin compararea măsurătorilor obținute de un radar cu o anumită limită. Măsurătorile situate peste această limită sunt asociate unor ținte reale, în timp ce acelea situate sub limita respectivă sunt considerate ca zgomot sau semnale perturbatoare. Țintele false, deci semnale de recepție asociate unor obiecte inexistente în realitate, consumă inutil resursele sistemului radar și pot conduce la nivelul autovehiculului la situații critice pentru siguranța șoferului și a traficului.

Limita de detecție trebuie aleasă pentru a maximiza probabilitatea de detecție, date fiind raportul semnal zgomot și probabilitatea alarmei false. În cazul în care parametrii statistici ai interferențelor sunt cunoscuți a priori, limita este aleasă în funcție de probabilitatea predefinită a alarmei false. Deseori însă forma funcției densitate de probabilitate a interferențelor este cunoscută, dar parametrii acesteia sunt necunoscuți sau se modifică în timp. Detecția bazată pe limita CFAR (Figura 22) urmărește în timp evoluția statistică a interferențelor și ajustează limita de detecție pentru a menține o probabilitate constantă a alarmelor false.

Atât semnalul util cât și interferențele au valori cu distribuții Rayleigh [17]. Datorită naturii aleatoare a ecourilor recepționate, gradul de performanță al sistemului de detecție are la bază funcții de probabilitate. Probabilitatea de detecție a unei ținte se notează cu P_D , iar probabilitatea unei alarme false se notează cu P_{FA} .

Rata de alarme false se calculează cu formula :

$$FAR = \frac{P_{FA}M}{T_M} = N_D P_{FA} \quad (3.4)$$

unde M reprezintă numărul de celule de rezoluție procesate într-un anumit interval de timp T_M , iar N_D este numărul de decizii luate în intervalul de timp. În general, o creștere semnificativă a ratei de alarme false conduce la o scădere substanțială a performanței sistemului radar.

Cum se arată în [8] capitolul 16:

$$P_{FA} = \exp\left(-\frac{T}{\sigma_i^2}\right) \quad (3.5)$$

cu σ_i^2 fiind puterea medie a interferențelor, iar T este pragul de detecție. Dat fiind un prag fix, creșterea nivelului mediu de interferențe cauzată de exemplu de un zgomot termic ridicat datorat supraîncălzirii circuitului de detecție sau a unui nivel ridicat al semnalelor perturbatoare, conduce la creșterea probabilității P_{FA} . Pe baza formulei de mai sus se observă că odată cu creșterea liniară a puterii medii a interferențelor cu un factor k , probabilitatea (subunitară) de alarme false crește exponențial, $P_{FA_final} = \sqrt[k]{P_{FA_initial}}$. Considerând pragul de detecție T fixat, o dublare a puterii medii a interferențelor ar conduce la creșterea unei probabilități inițiale exemplare de 10^{-4} la o probabilitate finală de alarmă falsă de 100 de ori mai mare, respectiv 10^{-2} .

Pentru a putea menține constantă probabilitatea de alarmă falsă într-un mediu cu interferențe variabile în timp și în spațiu, limita de detecție T trebuie modificată corespunzător. În general, $T = -\ln(P_{FA})\sigma_i^2$ poate fi exprimată ca un produs $T = \alpha\hat{g}$ între un parametru CFAR dependent de probabilitatea de alarme false dorită (α) și o mărime statistică asociată interferențelor (\hat{g}). Adaptarea limitei de detecție T la nivelul de interferențe perceptut de receptor conduce la modificarea capacității

acestui de detecție a țintelor, respectiv a probabilității de detecție P_D . Acest dezavantaj poate fi compensat prin creșterea energiei semnalului orientat spre o anumită țintă și în consecință prin creșterea raportului semnal-zgomot, SNR. P_D crește odată cu creșterea SNR.

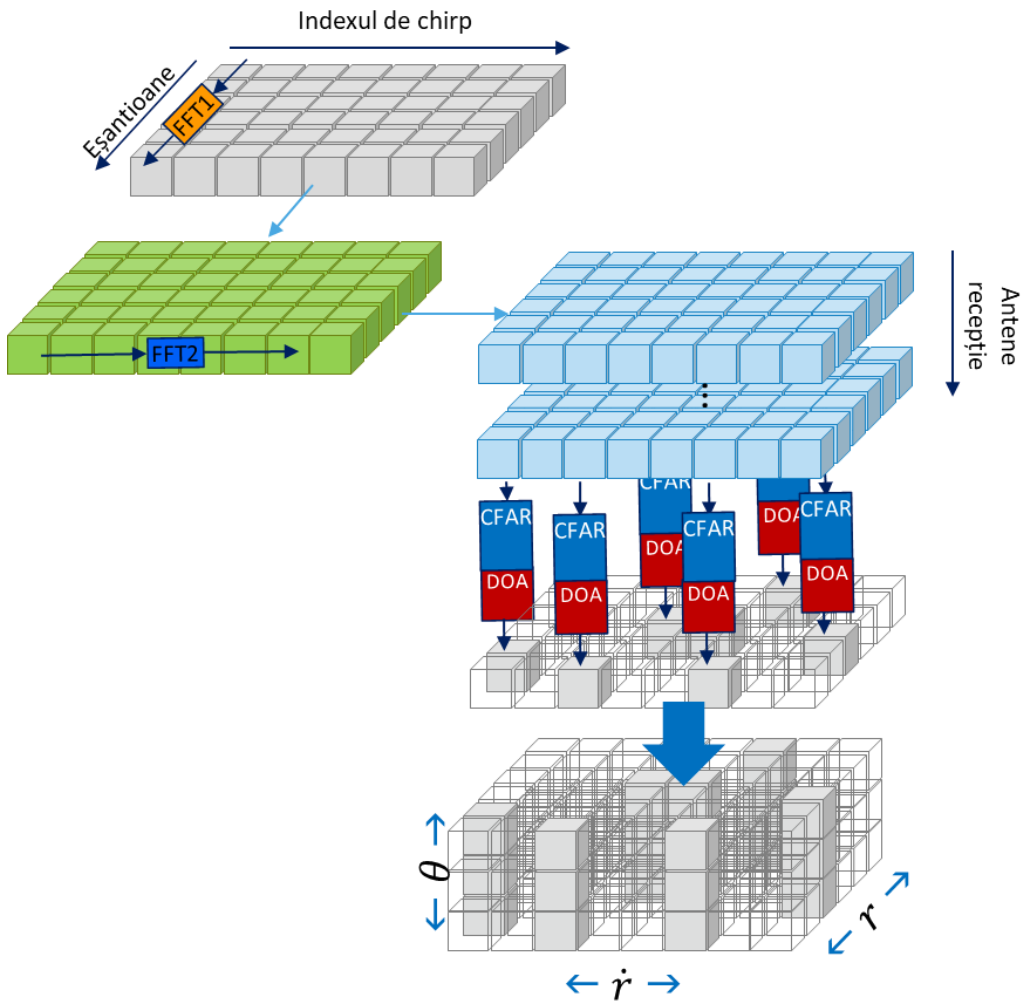


Figura 22: Algoritm de detecție CFAR

Algoritmul CA-CFAR (cell average CFAR) introdus în [18] este valabil în cazul unui mediu înconjurător omogen și are la bază un model simplificat care presupune că interferențele în fereastra anterioară respectiv posterioară de observație CFAR (Figura 23, G sunt celulele de rezoluție de protecție, CUT este celula de rezoluție testată) au distribuții independente și identice (IID), iar cele două ferestre de observație nu conțin ecouri reflectate de alte ținte învecinate.

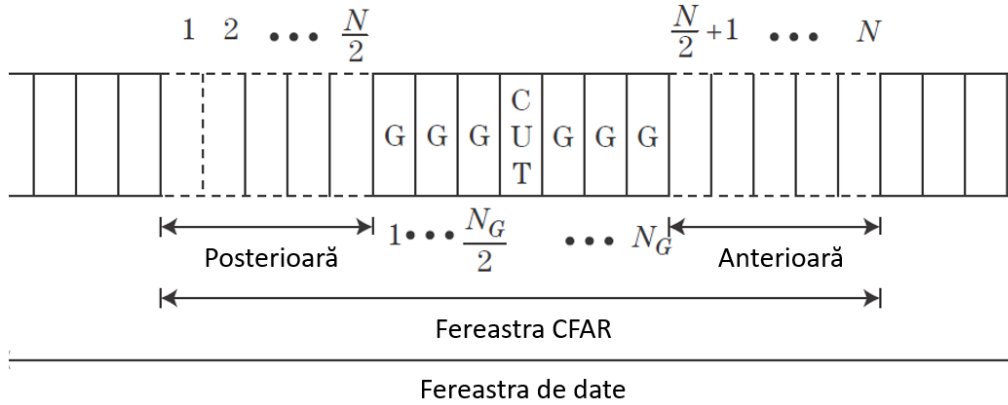


Figura 23: Fereastra CFAR unidimensională, sursă [8]

În aceste ipoteze și utilizând estimatorul ML (maximum likelihood, [19]) se obține puterea medie estimată a interferențelor:

$$\hat{\sigma}_i^2 = \frac{1}{N} \sum_{n=1}^N z_n, \quad \text{unde semalul observat } z = \{z_1, z_2, \dots, z_N\} \quad (3.6)$$

Pragul de detecție T_{FA} respectiv probabilitatea medie de alarme false \bar{P}_{FA} pentru algoritmul CA-CFAR vor fi în consecință:

$$T_{FA} = \alpha_{CA} \hat{\sigma}_i^2 \quad (3.7)$$

$$\bar{P}_{FA} = \left[1 + \frac{\alpha_{CA}}{N} \right]^{-N} \quad (3.8)$$

Detectorul radar CA-CFAR poate menține astfel o rată constantă de alarme false fără a cunoaște a priori puterea medie a interferențelor. Inversând relația (3.7) se observă că parametrul CFAR α_{CA} depinde doar de numărul de eșantioane din fereastra de observație CFAR (Figura 23) și de probabilitatea medie selectată pentru alarmele false.

Fenomenul de mascare a țintelor este notabil în medii eterogene, acolo unde apar ecouri corespunzătoare țintelor nu doar în celula de rezoluție testată (CUT) ci și într-una sau chiar în ambele ferestre de observație, anterioară respectiv posterioară. Acest lucru poate fi datorat fie prezenței țintelor extinse (subcapitolul 4.3) ori a mai multor ținte în zona de acoperire. Auto-mascarea apare atunci când o țintă ocupă fizic mai multe celule de rezoluție, astfel încât o parte din țintă este localizată în CUT, iar restul țintei produce ecouri radar în ferestrele de observație anterioară și/sau posterioară. Pragul de detecție este influențat negativ de aceste ecouri cu putere relativ mare față de cea a interferențelor. Mascarea reciprocă atunci când ecouri produse de alte ținte decât cea aflată în CUT intervin în ferestrele de observație, degradând astfel pragul de detecție.

În [20] și [21] este introdus algoritmul OS-CFAR (order statistics CFAR) care urmărește eliminarea efectului de mascare a țintelor. OS-CFAR ordonează cele N eșantioane din fereastra de observație CFAR și selectează primele k eșantioane pentru calculul parametrilor statistici ai interferențelor. În acest fel, algoritmul poate elimina efectul a până la N-k ținte adiacente, care maschează detecția țintei de interes CUT. În plus cu condiția ca $k > N/2$ [21] [22], OS-CFAR este capabil de a elimina alarme

false datorate reflexiilor perturbatoare provenite de la alte obiecte decât ținta de interes CUT.

În [22] se găsesc formulele pentru calculul probabilităților medii de detecție respectiv de alarme false:

$$P_{D.OS} = \prod_{i=0}^{k-1} \frac{N-i}{N-i + \frac{\alpha_{OS}}{1+SINR}} \quad (3.9)$$

și

$$P_{FA.OS} = \prod_{i=0}^{k-1} \frac{N-i}{N-i + \alpha_{OS}} \quad (3.10)$$

unde $SINR = \sigma_t^2 / \sigma_i^2$, σ_t^2 fiind parametrul statistic asociat distribuției țintei.

Gradul de incertitudine, respectiv varianța asociată distribuției interferențelor conduce la un prag de detecție mai ridicat decât cel al detectorului Neyman-Pearson [8], data fiind o anumită probabilitate pentru alarme false. Pentru a putea obține probabilitatea de detecție dorită, pragul crescut conduce la un raport SINR mai ridicat față de cel al detectorului Neyman-Pearson. Atenuarea CFAR este definită ca și raportul între SINR necesar unui detector CFAR și SINR necesar unui detector Neyman-Pearson.

Atenuarea asociată unui detector OS-CFAR este analizată în [21] și [23]. Aceasta este minimă pentru $k = 3N/4$. Această valoare a lui k permite eliminarea a până la $N/4$ ținte perturbatoare. Pentru aceeași valoare a lui N , OS-CFAR are o atenuare mai mare decât CA-CFAR. Dată fiind capacitatea OS-CFAR de a elimina efectul de mascare mutuală între ținte, lungimea ferestrei de observație poate fi mărită pentru a reduce atenuarea CFAR. Performanțe de detecție similare se obțin într-un mediu cu interferențe omogene utilizând CA-CFAR cu $N = 16$ sau OS-CFAR cu $N = 24$, $k = 18$ [21]. OS-CFAR poate fi utilizat și pentru evitarea efectului de auto-mascare.

3.4 Percepția țintelor în mișcare

Procesarea Doppler a semnalului de recepție urmărește două scopuri primare, bazate pe extragerea informației conținute de către variația Doppler. În primul rând, se dorește detecția țintelor de interes aflate în mișcare într-un mediu înconjurător cu interferențe predominant cauzate de obiecte reflectante diferite de țintele de interes, de exemplu copaci, șosele sau parapetei de îngrădire a tronsoanelor de carosabil aflate în construcție. În al doilea rând, se urmărește măsurarea variației Doppler și ulterior calculul vitezei radiale a țintelor detectate din zona de acoperire. Procesul de percepție a țintelor aflate în mișcare se adresează primului scop, în timp ce procesarea impuls-Doppler (subcapitolul 3.5) este destinată celui de-al doilea scop.

Percepția țintelor aflate în mișcare (moving target indication, MTI) se limitează la analiza semnalului în timp lent (Figura 11) exclusiv în domeniul timp, de regulă utilizând un singur filtru trece sus. Această filtrare este efectuată pentru fiecare celulă de rezoluție, într-o perioadă de timp de mai multe impulsuri succesive din trenul de impulsuri. MTI produce rezultate relativ simple însă cu un efort computațional foarte mic. Pe de altă parte, procesarea impuls-Doppler necesită transformarea semnalului din domeniul timp în domeniul frecvență și produce un set de date cu

valoare ridicată, contribuind substanțial la îmbunătățirea raportului semnal-interferență.

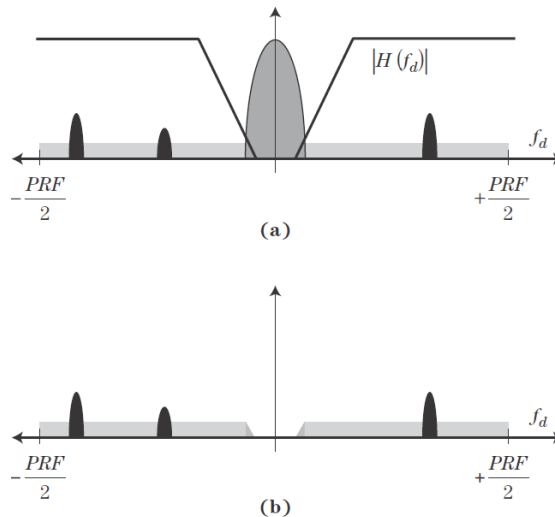


Figura 24: Efectul filtrării MTI „trece sus”, sursă [8]

În filtrarea prezentată în Figura 24 se presupune că pe baza informațiilor cunoscute legate de mișcarea proprie a senzorului se obține o centrare a spectrului reflexiilor parazitare la frecvența Doppler zero. Semnalul în domeniul timp rezultat la ieșirea filtrului trece sus $H(f_d)$ va conține zgomotul și ecurile datorate uneia sau mai multor ținte. Dacă amplitudinea acestui semnal este mai mare decât pragul detectorului, atunci acesta va fi marcat ca aparținând unei ținte de interes, altfel acesta va fi catalogat ca fiind rezultat exclusiv al unor interferențe.

De remarcat este faptul că rezultatul procesului de percepție a țintelor aflate în mișcare este doar informația legată de prezența sau absența țintelor în mișcare în fiecare celulă de rezoluție, fără a oferi detalii suplimentare legate de direcția sau viteza de deplasare a țintei. De asemenea, în cazul în care mai multe ținte sunt în mișcare în aceeași celulă de rezoluție, rezultatul detectorului va fi tot „țintă prezentă”.

3.5 Procesarea impuls – Doppler

Rezultatul procesării impuls-Doppler este o matrice de date, cu dimensiunile timp rapid, respectiv frecvența Doppler. Principiul de bază constă în analiza spectrală a semnalului în timp lent corespunzător fiecărei celule de rezoluție [24], [25]. Energia semnalului reflectat de către o țintă în mișcare este separată de cea provenită de la ecuri parazitare (Figura 25). În plus, spectrul de frecvență a semnalului în timp lent obținut prin FFT permite estimarea variației de frecvență Doppler, deci a diferenței de viteză radială între senzor și țintă. De asemenea, el poate conține ecurile produse de mai multe ținte dacă acestea sunt separabile în domeniul frecvență, respectiv au viteze radiale suficient de distanțate pentru o celulă de rezoluție dată (Figura 26).

Procesarea impuls-Doppler utilizează un număr mai mare de eșantioane decât algoritmul de percepție a țintelor în mișcare și realizează în acest fel o amplificare integrală superioară și o creștere mai mare a raportului semnal-zgomot. Dezavantajele majore constau în complexitatea de calcul crescută față de cea pentru

MTI și în timpul de iluminare a țintelor de asemenea mai mare, necesar pentru a extrage variația Doppler din spectrul de frecvență a semnalului în timp lent.

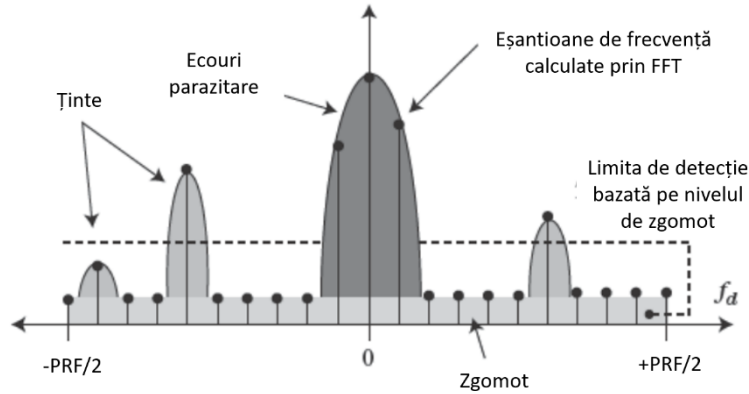


Figura 25: Procesare impuls-Doppler

Figura 25 prezintă modul de funcționare a algoritmului impuls-Doppler. După transformarea Fourier prin FFT a semnalului în timp lent, se obține un număr de K eșantioane sau puncte de sprijin a spectrului acestui semnal în intervalul Doppler $[-PRF/2, +PRF/2]$. Numărul de puncte de sprijin în frecvență K este de regulă egal sau mai mare decât numărul de eșantioane preluate din semnalul în domeniul timp, M . Zgomotul termic este prezent în fiecare din eșantioanele de frecvență, având o putere medie constantă. Energia spectrală a ecourilor parazitare este concentrată în jurul frecvenței Doppler zero, acolo unde zgomotului termic este mult mai mic decât ecourile parazitare și poate fi neglijat. O țintă poate apărea oriunde în intervalul Doppler, corespunzător vitezei sale de deplasare. Pentru detecția țintelor, energia acestora este comparată cu o limită calculată pe baza nivelului de zgomot. Doar țintele cu frecvențe peste această limită vor fi detectate. În Figura 25, doar două din cele trei ținte reale vor fi detectate. De regulă, eșantioanele corespunzătoare ecourilor parazitare sunt eliminate, fiind inutile în procesul de detecție.




Figura 26: Harta impuls-Doppler pentru nouă ținte, sursă [24]

3.6 Compressive sensing

Acest subcapitol prezintă într-o formă actualizată rezultatele experimentale publicate în [26]. Așa cum s-a arătat în subcapitolul anterior 3.5, determinarea variației Doppler se face transformând semnalul în timp lent, corespunzător unei celule de rezoluție, din domeniul timp în domeniul frecvență utilizând FFT. Transformata Fourier aplicată semnalului recepționat în timp rapid corespunzător unui impuls este folosită pentru extragerea informației legate de distanța dintre senzor și țintă.

Conform teoremei de eșantionare Whittaker-Kotelnikov-Shannon (WKS) [27], semnalul recepționat având limita maximă a benzii de frecvență ω_M poate fi reconstruit din eșantioanele sale discrete, preluate la momentele de timp nT_s dacă frecvența de eșantionare este cel puțin de două ori mai mare decât lățimea de bandă $\omega_s \geq 2\omega_M$. Frecvența minimă de eșantionare se numește frecvența Nyquist, iar T_s reprezintă pasul de eșantionare. În aceste condiții, semnalul poate fi exprimat în funcție de eșantioanele sale, prin interpolare sinc:

$$y(t) = \sum_{k=-\infty}^{\infty} y(kT_s) \frac{2\omega_c}{\omega_s} \text{sinc}(\omega_c(t - kT_s)) \quad (3.11)$$

unde ω_c este frecvența de tăiere a unui filtru trece jos cu $\omega_M \leq \omega_c \leq \omega_s - \omega_M$.

În [28] și [29], s-a arătat că semnalul poate fi reconstruit, chiar dintr-un număr mai mic de eșantioane decât cel cerut de teorema de eșantionare, dacă semnalul este sparse în domeniul frecvență. Un semnal este denumit sparse dacă majoritatea coeficienților reprezentării sale în domeniul transformatei sunt zero și doar un număr mic de coeficienți sunt nenuli. În acest caz, el poate fi reconstituit dintr-un număr redus de observații din domeniul sparse.

Semnalul y cu lungimea N poate fi reprezentat ca și o combinație liniară într-o bază Ψ , aleasă potrivit pentru fiecare aplicație:

$$y = \Psi c \quad (3.12)$$

unde c sunt coeficienții. În cazul nostru, baza este transformata Fourier discretă (DFT) pentru algoritmul Orthogonal Matching Pursuit (OMP), respectiv transformata cosinus discretă (DCT) pentru algoritmul l1-magic. Semnalul în banda de bază pentru rapid chirps este compus dintr-o sumă de semnale sinus cu componente complexe (deci în fază și în cuadratură). Acestea sunt sparse în domeniile transformatei menționate, având majoritatea coeficienților egali cu zero.

Semnalul y este eșantionat neuniform, obținându-se astfel vectorul b , prin intermediul operatorului liniar:

$$b = \Phi y = \Phi \Psi c = A c \quad (3.13)$$

Astfel se obține un număr mai mic de eșantioane M , unde $M < N$. Φ reprezintă o matrice de măsurători cu dimensiunea $M \times N$. Pentru reconstrucția semnalului, coeficienții sunt calculați rezolvând ecuația:

$$A x = b, \text{ unde } A = \Phi \Psi \quad (3.14)$$

După acest pas, semnalul poate fi reconstruit cu ajutorul coeficienților x calculați mai sus, folosind inversa transformatei inițiale:

$$\hat{y} \approx \Psi x \quad (3.15)$$

Problema constă în a găsi algoritmul optim pentru a reconstitui semnalul y utilizând doar un număr de M măsurători. Una din modalitățile posibile este de a minimiza norma l_1 . Această problemă de optimizare convexă este redusă în [30] la un algoritm liniar numit algoritmul de căutare primară (basis pursuit) cu complexitate de calcul $O(N^3)$. Pentru algoritmul l_1 -magic, s-a utilizat varianta Min- l_1 , cu constrângerea [31]: $\min \|x\|_1$, astfel încât $Ax = b$. Algoritmul identifică vectorul cu cea mai mică normă l_1 , $\|x\|_1 = \sum_i |x_i|$, care justifică observațiile din vectorul b . Dacă există un x_0 compact, astfel încât $Ax_0 = b$ atunci acest algoritm îl găsește. Programul are la bază metode standard cu puncte interioare, fiind implementat ca și program liniar cu metodă cu puncte primare-secundare [31].

Cealaltă metodă analizată în continuare este numită căutarea potrivirilor ortogonale (orthogonal matching pursuit, OMP). Aceasta este o metodă consumatoare de resurse computaționale care încearcă iterativ să găsească atomi dintr-un dicționar folosit, prin care să aproximeze cât mai exact proprietățile unui semnal dat. Algoritmul este construit în așa fel încât să aproximeze la fiecare iterație cât mai exact semnalul de reprezentat, încercând la final să ofere un rezultat satisfăcător [32].

În continuare se consideră scenariul descris în [24] cu nouă ținte care au distanțe și viteze nesingulare. Parametrii esențiali ai simulării sunt:

- banda de frecvență baleiată, $f_{sweep} = 150$ MHz
- distanța maximă detectabilă, $R_{max} = 200$ m
- viteza radială maximă detectabilă, $v_{rmax} = 250$ km/h
- numărul de impulsuri, $L = 256$
- numărul de eșantioane pe impuls, $N=1100$
- analiză FFT cu NFFT = 2048 puncte.

Cele nouă ținte au următoarele poziții respectiv viteze:

$$R_p = [10 \ 20 \ 40 \ 50 \ 65 \ 65 \ 70 \ 80 \ 100] \ [m]$$

$$v_{r,p} = [30 \ 30 \ 45 \ 55 \ 60 \ 120 \ 20 \ 10 \ 75] \ [km/h]$$

Semnalul decirpat din banda de baza este un semnal complex format dintr-o componentă în fază și una în cuadratură, cu nouă valori ale frecvenței corespunzătoare celor noua ținte. Se consideră două cazuri, unul fără zgomot, iar unul cu zgomot.

$$y[n] = \sum_{p=1}^9 A_p \exp(j2\pi f_{B_p} nT_s) + w_I[n] + jw_Q[n]$$

Zgomotul este alb, gaussian și aditiv (AWGN) cu $w_{I,Q}[n] \sim N(0,1)$. Amplitudinile A_p corespunzătoare fiecărei ținte sunt diferite, conducând la următoarele valori diferite ale rapoartelor semnal/zgomot per țintă:

$$[-14.54 \ -8.52 \ -5 \ -2.5 \ -0.56 \ 1.02 \ 2.35 \ 3.51 \ 4.54] \ [dB]$$

Pentru reconstrucția compressive sensing se consideră variante ale algoritmilor OMP și l_1 -magic cu număr M diferit de eșantioane prelevate neuniform: $N/2$, $N/4$ și $N/8$. În ambele cazuri, fără respectiv cu zgomot, se analizează reconstrucția semnalului în domeniul timp (componentele I și Q) și în domeniul frecvență (prima respectiv a doua transformare FFT și reprezentarea în diagrama distanță-Doppler).

Componenta în fază a decalajului de frecvență pentru impulsul 256 (corespunzător unei celule de rezoluție 256) este reprezentată în Figura 27 pentru cazul fără zgomot, respectiv în Figura 28 pentru cazul cu zgomot. În ambele cazuri se preiau neuniform $N/4$ eșantioane.

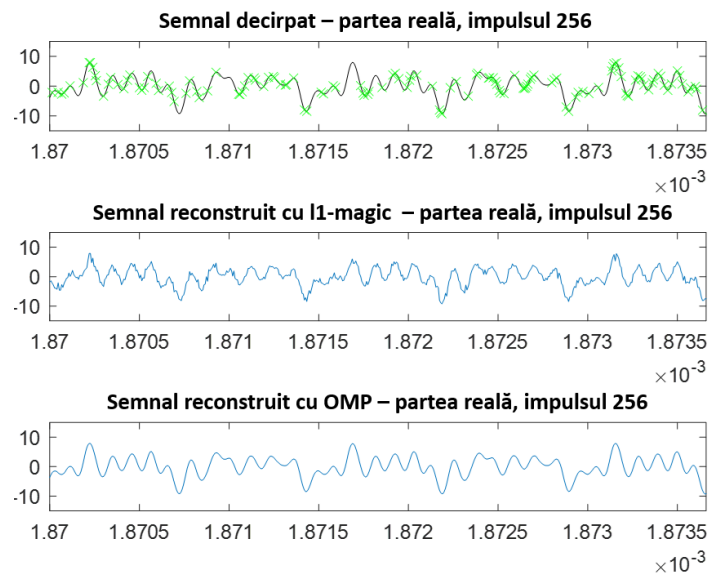


Figura 27: Semnal fără zgomot. Sus: componenta în fază a impulsului 256 – original și cu $N/4$ eșantioane prelevate neuniform marcate cu verde. Mijloc: semnal reconstruit cu l1-magic. Jos: semnal reconstruit cu OMP. Axa x în [s].




Figura 28: Semnal cu zgomot. Sus: componenta în fază a impulsului 256 – original și cu $N/4$ eșantioane prelevate neuniform marcate cu verde. Mijloc: semnal reconstruit cu l1-magic. Jos: semnal reconstruit cu OMP. Axa x în [s].

Analiza în domeniul timp arată că în ambele cazuri, reconstrucția OMP oferă rezultate superioare atât din punct de vedere subiectiv (vizual) cât și obiectiv, pe baza erorii medii pătratice, MSE:

$$MSE = \frac{1}{N} \sum_{n=1}^N (\hat{y}[n] - y[n])^2$$

Valorile pentru MSE sunt prezentate în Tabel 1. Se poate observa că pentru un număr mare de eșantioane neuniforme ($M=N/2$), eroarea medie pătratică este mică și crește odată cu scăderea lui M . Eroarea MSE este mai mică în cazul semnalului fără zgomot față de cel afectat de zgomot. În toate cazurile, valorile minime se obțin pentru algoritmul OMP.

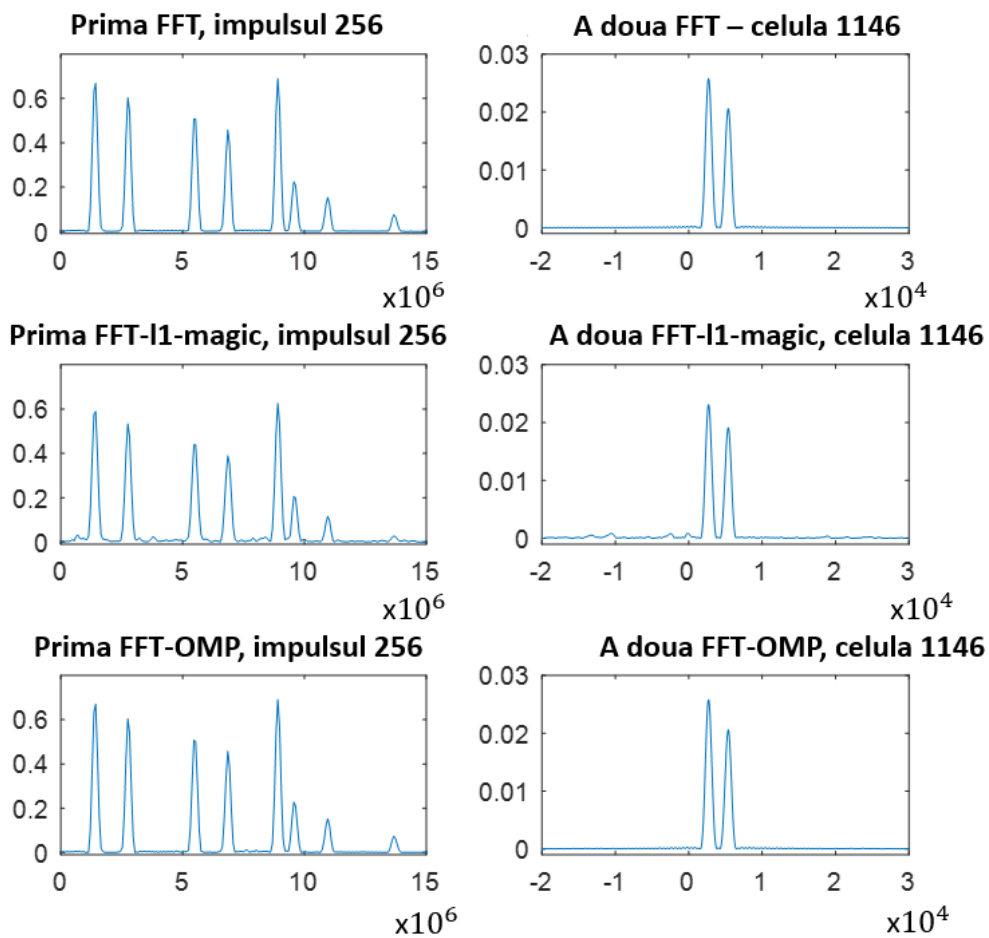


Figura 29: Semnal fără zgomot – domeniul frecvența, după prima și respectiv a doua transformare FFT. Sus este reprezentat cazul tradițional cu eșantionare uniformă. La mijloc și jos, cazul reconstrucției compressive sensing pentru $N/4$ eșantioane. Stânga, prima transformare FFT pentru semnalul original, reconstruit cu I1-magic și reconstruit cu OMP. Dreapta, a doua transformare FFT, pentru celula de rezoluție cu două ținte aflate la aceeași distanță ($R = 65$ m), dar cu viteze diferite, pentru semnalul original, reconstruit cu I1-magic și reconstruit cu OMP. Axa x în [Hz].

Tabel 1: MSE pentru metodele de reconstrucție cu compressive sensing

Număr de eșantioane prelevate neuniform	MSE			
	Semnal		Semnal+ zgomot	
	l1-magic	OMP	l1-magic	OMP
$N/2$ eșantioane	0.0615	0.0007	1.2413	1.1603
$N/4$ eșantioane	0.8090	0.0055	2.5862	1.5239
$N/8$ eșantioane	2.7769	0.8056	4.7765	4.1748

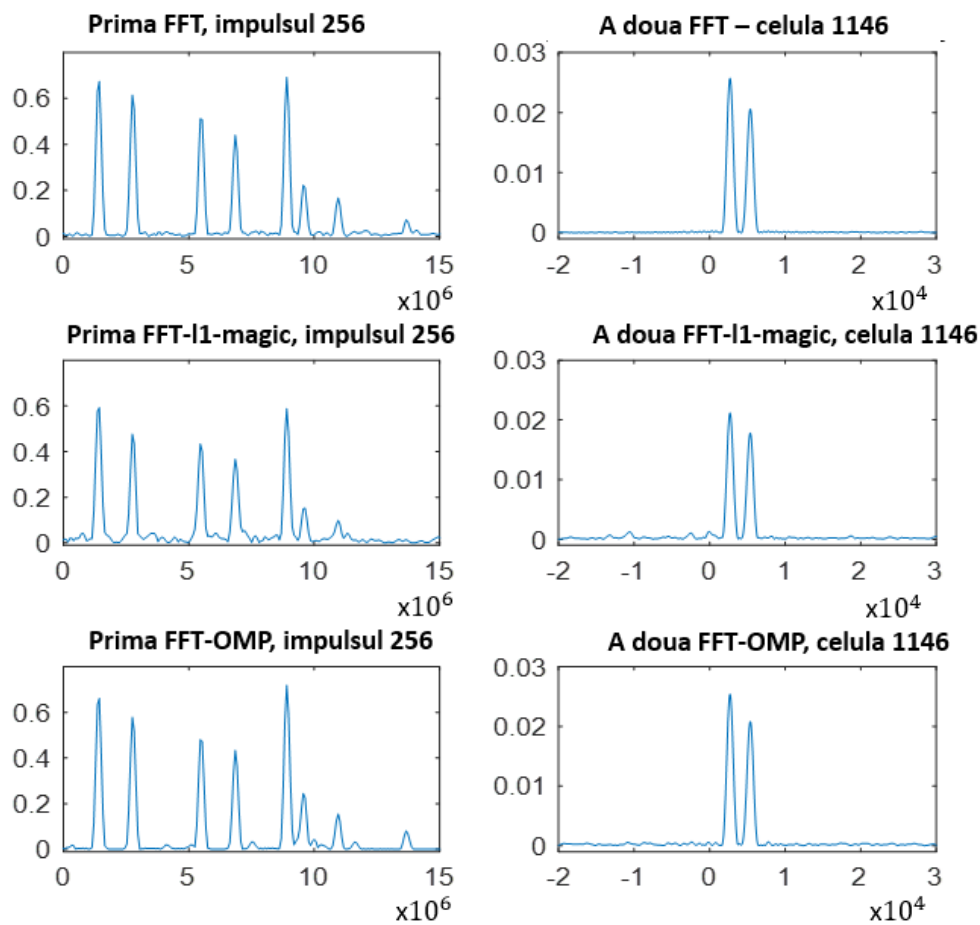


Figura 30: Semnal afectat de zgomot – domeniul frecvența, după prima și respectiv a doua transformare FFT. Sus este reprezentat cazul tradițional cu eșantionare uniformă. La mijloc și jos, cazul reconstrucției compressive sensing pentru $N/4$ eșantioane. Stânga, prima transformare FFT pentru semnalul original, reconstruit cu l1-magic și reconstruit cu OMP. Dreapta, a doua transformare FFT, pentru celula de rezoluție cu două ținte aflate la aceeași distanță ($R = 65$ m), dar cu viteze diferite, FFT pentru semnalul original, reconstruit cu l1-magic și reconstruit cu OMP. Axa x în [Hz].

În continuare, sunt prezentate rezultatele simulărilor cu $N/4$ eşantioane prelevate neuniform, care oferă un rezultat similar cu cazul a $N/2$ eşantioane, având însă o complexitate de calcul mai scăzută. Sunt analizate și spectrele de frecvență: în Figura 29 și în Figura 30 se regăsesc prima și a doua transformată Fourier pentru semnalele fără respectiv cu zgomot. Spectrul semnalului original are după prima transformată Fourier opt maxime, deoarece două dintre ținte se află la aceeași distanță, dar au viteze diferite.

În cazul reconstrucției cu l1-magic, se poate observa că și atunci când semnalul nu este afectat de zgomot, amplitudinile din spectru sunt atenuate la toate frecvențele, îngreunând astfel detecția țintelor (Figura 29). Pentru semnalul afectat de zgomot, unele ținte cu greu mai pot fi detectate în impulsul 256 (Figura 30).

În cazul reconstrucției cu OMP pentru semnalul fără zgomot, spectrul nu este atenuat (Figura 29). Pentru semnalele afectate de zgomot, maximele ecourilor produse de ținte sunt vizibile clar, chiar mai bine decât în spectrul semnalului original.

A doua transformare FFT, calculată pentru celula de rezoluție 1146, arată din nou atenuarea produsă de l1-magic, comparativ cu spectrul semnalului original.

Pentru OMP, a doua transformată Fourier pentru celula de rezoluție 1146 are spectrul neatenuat pentru ambele cazuri, cu respectiv fără zgomot.

După simularea celor trei variante, cu $N/2$, $N/4$ și $N/8$ eşantioane prelevate neuniform, se observă că procesul de eşantionare trebuie efectuat cu minim un sfert din numărul de valori ale semnalului original. Varianta cu $N/8$ conduce la rezultate slabe, deoarece spectrul este atenuat și deformat pentru ambele metode de reconstrucție, chiar și în cazul semnalului fără zgomot (Figura 31).

Tabel 2: Timpii de calcul pentru cei doi algoritmi compressive sensing

Număr de eşantioane prelevate neuniform	Timp (secunde)	
	l1-magic	OMP
$N/2$ eşantioane	301.80	441.94
$N/4$ eşantioane	139.13	73.59
$N/8$ eşantioane	95.85	20.33

În implementarea actuală, timpul de procesare scade odată cu reducerea numărului de eşantioane prelevate neuniform, M (Tabel 2). Timpul de execuție al algoritmului OMP este mai mare decât cel corespunzător algoritmului l1-magic pentru $M=N/2$, însă mai redus pentru celelalte două variante, cu $M=N/4$ și $N/8$. Pentru valoarea selectată de $N/4$ eşantioane prelevate neuniform, timpul de procesare a OMP este aproximativ jumătate față de l1-magic, fiind deci net superior. Trebuie menționat ca Tabelul 2 nu se refera la timpul necesar calculului diagramei range-Doppler care folosește transformarea FFT. Timpii de calcul indicați sunt derivați din implementări neoptimizate și neaccelerate și trebuie privite ca și unități relative de masura permițând o comparație a performanței între cei doi algoritmi.

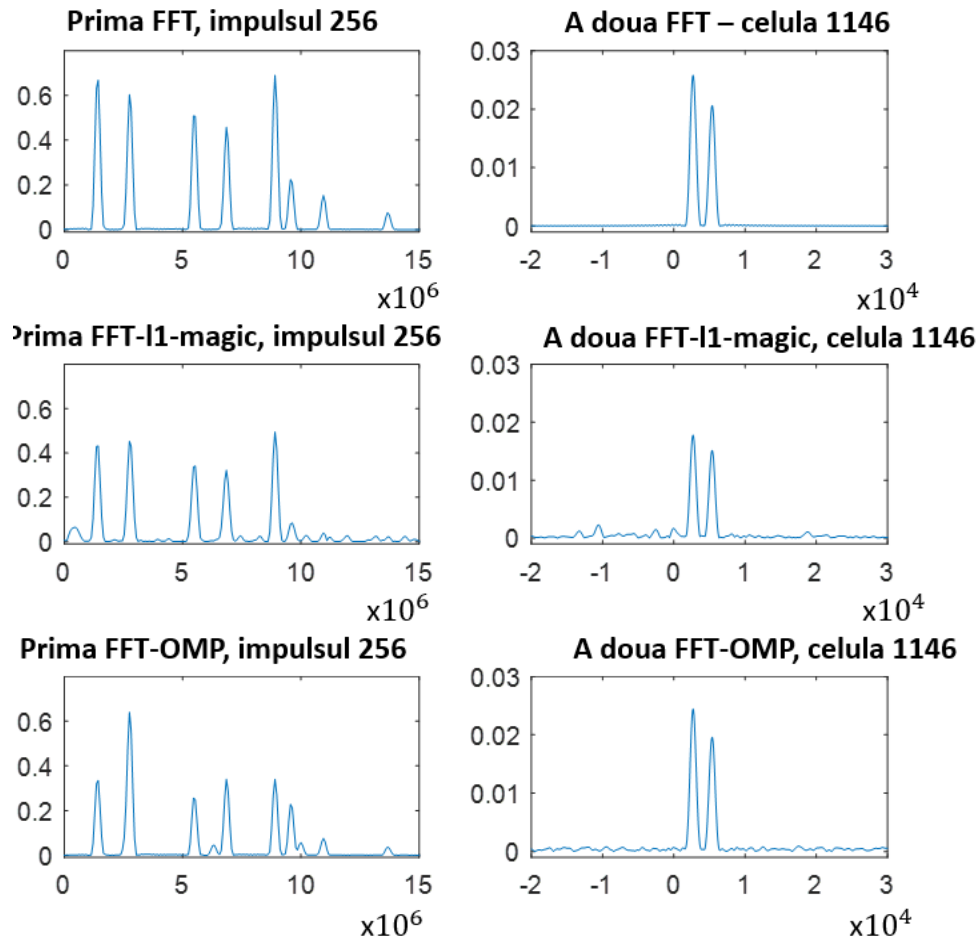


Figura 31: Semnal fără zgomot – domeniul frecvența, după prima și respectiv a doua transformare FFT. Sus este reprezentat cazul tradițional cu eșantionare uniformă. La mijloc și jos, cazul reconstrucției compressive sensing pentru $N/8$ eșantioane. Stânga, prima transformare FFT pentru semnalul original, reconstruit cu l1-magic și reconstruit cu OMP. Dreapta, a doua transformare FFT, pentru celula de rezoluție cu două ținte aflate la aceeași distanță ($R = 65$ m), dar cu viteze diferite, pentru semnalul original, reconstruit cu l1-magic și reconstruit cu OMP. Axa x în [Hz].

Rezultatele sunt confirmate și prin diagramele distanță-Doppler (Figurile 32 - 37) cu $N/4$ eșantioane. Țintele sunt detectabile în ambele cazuri, atât pentru OMP cât și pentru l1-magic. Cu un prag de detecție fix, cele nouă ținte sunt detectate corect cu vitezele și distanțele corespunzătoare, pentru ambii algoritmi. Amplitudinile prezentate în diagramele distanță-Doppler sunt mai mici pentru l1-magic și în plus pot apărea componente spectrale nejustificate care conduc la alarme false dacă pragul de detecție este prea mic. Acest fenomen poate fi contracarat prin ajustarea pragului de detecție.




Figura 32: Diagrama distanță-Doppler pentru semnalul fără zgomot, eșantionare uniformă




Figura 33: Diagrama distanță-Doppler pentru semnal cu zgomot, eșantionare uniformă




Figura 34: Diagrama distanță-Doppler pentru semnalul fără zgomot, reconstrucție l1-magic, N/4 eșantioane prelevate neuniform




Figura 35: Diagrama distanță-Doppler pentru semnalul cu zgomot, reconstrucție l1-magic, N/4 eșantioane prelevate neuniform

Analiza efectuată în domeniile timp și frecvență demonstrează că se pot utiliza cu succes tehnicile compressive sensing pentru a reduce numărul de eșantioane al semnalelor radar de tip rapid chirps. Comparația dintre cei doi algoritmi studiați, OMP și l1-magic arată clar avantajele și performanțele superioare ale OMP, în ambele domenii, timp respectiv frecvență. Este posibilă reducerea numărului de eșantioane cu factorul patru (în cazul studiat $M = 70400$ din $N = 281600$ pentru toate cele 256 de impulsuri), permițând în același timp detecția tuturor țintelor, chiar și în condiții de zgomot.

În concluzie, cerințele actuale ale sistemelor radar îmbarcate în autoturisme pot fi îndeplinite de către semnale de tip rapid chirps. Acestea permit detecția simultană a distanței și vitezei radiale corespunzătoare unui număr ridicat de ținte din zona de acoperire. Reducerea numărului de eșantioane prelevate și prelucrate utilizând reconstrucția semnalului original bazată pe compressive sensing reduce necesarul de memorie al unui radar și în consecință prețul acestuia.




Figura 36: Diagrama distanță-Doppler pentru semnalul fără zgomot, reconstrucție OMP, N/4 eşantioane prelevate neuniform




Figura 37: Diagrama distanță-Doppler pentru semnalul cu zgomot, reconstrucție OMP, N/4 eşantioane prelevate neuniform

3.7 Estimarea parametrilor unui obiect

În diverse aplicații tehnice, de exemplu în sistemele radar imbarcate în autoturisme [33], [34] sau în sistemele digitale de recunoaștere a vocii, se pune problema estimării unui parametru sau a unui set de parametri pe baza unei mulțimi finite de eşantioane ale unui semnal electric variabil în timp. Astfel, dată fiind mulțimea $[x_0, x_1, \dots, x_{N-1}]$ care constă din eşantioane ale unui parametru fizic θ , se dorește determinarea unui estimator cât mai bun, care aproximează cât mai exact valoarea reală a lui θ :

$$\hat{\theta} = g([x_0, x_1, \dots, x_{N-1}]) \quad (3.16)$$

În mod evident există mai multe posibilități de estimare a parametrului θ , de exemplu luând valoarea medie a eşantioanelor $\frac{1}{N} \sum_{i=0}^{N-1} x_i$, sau alternativ selectând primul eşantion x_0 din mulțimea de valori. Pentru primul estimator este necesară achiziția tuturor eşantioanelor, ceea ce implică un timp mai îndelungat pentru estimarea valorii reale a lui θ . Al doilea estimator permite un calcul mult mai rapid însă pe de altă parte este, în cele mai multe cazuri, mai puțin apropiat de θ . Limita inferioară Cramer-Rao permite determinarea estimatorului optim.

Prin definiție, varianța unei variabile este

$$\sigma^2 = \frac{1}{N} \sum_{i=0}^{N-1} (x_i - \bar{x})^2, \text{ unde } \bar{x} = \frac{1}{N} \sum_{i=0}^{N-1} x_i \quad (3.17)$$

Limita inferioară Cramer-Rao (CRLB) poate fi aplicată doar estimatorilor fără bias, adică acelor estimatori care tind în medie către valoarea adevărată a parametrului necunoscut θ :

$$\mathbb{E}(\hat{\theta}) = \theta, \forall \theta \in (a, b), \text{ unde } \mathbb{E}(\hat{\theta}) = \int \hat{\theta} p(x; \theta) dx \text{ și } x = [x_0, x_1, \dots, x_{N-1}]^T \quad (3.18)$$

Un estimator nedeplasat nu este neapărat un estimator bun ci el doar garantează că în medie, utilizând un număr mare de eșantioane, va reda valoarea reală adică cea corectă a parametrului θ .

Criteriul de selecție a estimatorului optim nedeplasat este valoarea varianței sale. În consecință, estimatorul cu varianță minimă este cel mai bun pentru parametrul θ . Acest estimator cu varianță minimă nedeplasat (minimum variance unbiased, MVU) nu există neapărat. Deși există și alte limite care permit selecția estimatorului potrivit, limita inferioară dată de teorema Cramer-Rao [19] este cea care poate fi calculată cel mai simplu, având astfel o relevanță practică deosebită.

Având în vedere că întreaga informație avută la dispoziție provine din eșantioanele măsurate, respectiv din funcția densitate de probabilitate (PDF), este evident că gradul de calitate al unui estimator depinde direct de PDF. Ceea ce interesează pentru evaluarea performanței unui estimator este viteza cu care se modifică funcția sa de verosimilitate $L(\theta) = \sum_{i=0}^{N-1} p^{x_i}(1-p)^{1-x_i}$, respectiv a doua derivată relativ la parametrul θ a acestei funcții. Deoarece derivarea unui produs de funcții este complexă și luând în considerare monotonia funcției logaritm pentru calculul variantei minime se ia în considerare logaritmul natural al funcției de verosimilitate a unui estimator $\ln(L(\theta))$.

Avantajele calculului derivatei sunt datorate proprietăților funcției logaritm.

$$\ln(ab) = \ln(a) + \ln(b) \text{ și } \ln(a^N) = N\ln(a) \quad (3.19)$$

Teorema Cramer-Rao [19]: În condiția în care densitatea de probabilitate satisface condiția de regularitate:

$$\mathbb{E} \left[\frac{d \ln(p(x, \theta))}{d\theta} \right] = 0, \forall \theta \in (a, b) \quad (3.20)$$

atunci varianța oricărui estimator nedeplasat nu poate fi mai bună, deci mai redusă decât limita:

$$\text{var}(\hat{\theta}) \geq -1 / \mathbb{E} \left[\frac{d^2 \ln(p(x, \theta))}{d\theta^2} \right] \quad (3.21)$$

În sistemele radar teorema Cramer-Rao se aplică pentru estimarea decalajului τ de timp între semnalul în timp rapid transmis cu lățimea de bandă B și ecoul corespunzător întârziat proporțional cu distanța între senzor și țintă. În concluzie, cu cât mai mare este lățimea de bandă și raportul semnal-zgomot, cu atât mai probabilă este aplicarea unui estimator cu varianță mică, deci performant [35].

4 ALGORITMI DE TRACKING

Un senzor radar permite măsurarea distanței relative între originea unui sistem de referință, dat în general de poziția de instalare a senzorului în autovehicul, și țintă. O metodă uzuală de reprezentare a rezultatelor acestor măsurători este diagrama distanță – timp, care indică pozițiile țintelor identificate în funcție de timp. Obiectivul principal al algoritmilor de urmărire (tracking) a țintelor este de a estima traiectoria de deplasare a unei ținte, fie ea un obiect în mișcare sau unul care are capacitatea de a se deplasa.

4.1 Modele de mișcare a țintelor punctiforme

Deși o țintă reală nu este aproape niciodată un punct singular în spațiu iar informațiile legate de orientarea sa sunt importante pentru urmărire, o țintă poate fi considerată prin simplificare ca fiind un obiect punctiform, fără o formă specifică. Modelul de mișcare a țintelor punctiforme descrie modul în care starea unei astfel de ținte evoluează în funcție de timp. Acesta include poziția sa geometrică în spațiu și stările cinematice care descriu mișcarea obiectului de interes, cum ar fi de exemplu, viteza, accelerația sau viteza sa de rotație. În plus, modelul poate descrie modul de modificare a formei unei ținte în timp (de obicei când aceasta se rotește) și modul în care numărul de detecții per țintă variază în timp (de regulă numărul de ecouri recepționate crește cu cât obiectul urmărit se apropie de senzor).

Aproape toate metodele de urmărire a țintelor propulsate sunt bazate pe modele matematice. Ele presupun că mișcarea ținte și observațiile legate de aceasta pot fi reprezentate prin modele matematice cunoscute, care permit o precizie suficient de bună pentru o anumită problemă dată. Modelele utilizate cel mai frecvent sunt cele cunoscute sub numele de modele în spațiul de stări, având forma următoare [36]:

$$x_{k+1} = f_k(x_k, u_k) + w_k \quad (4.1)$$

$$z_k = h_k(x_k) + v_k \quad (4.2)$$

unde x_k, z_k și u_k reprezintă vectorul de stare a ținte, vectorul de observație și respectiv vectorul de control la un anumit moment de timp t_k ; w_k și v_k sunt zgomotele de proces respectiv de măsură, iar f_k și h_k sunt funcții de transfer cu valori vectoriale. Starea următoare x_{k+1} a unui obiect în mișcare depinde deci exclusiv de starea sa actuală x_k și de vectorul de control instantaneu u_k . În cazul unui autoturism, vectorul de control reprezintă acțiunea șoferului în procesul de control al mașinii, de exemplu când acesta apasă pedala de accelerație, de frână sau manevrează volanul. În problemele de urmărire a țintelor, acest vector de control este de regulă necunoscut. Zgomotul de proces w_k , rezultat de exemplu datorită unei rafale puternice de vânt, influențează la rândul său starea ulterioară la momentul de timp t_{k+1} . Observația făcută de un senzor depinde de un moment dat doar de starea reală x_k a obiectului observat și de zgomotul sistemului de măsură v_k , considerat ca fiind aditiv.

Deoarece mișcările țintelor au loc în mod continuu, iar observațiile făcute de sistemul senzorial sunt discretizate, deci eșantionate la anumite momente de timp și

cuantizate, modelul de reprezentare matematică a mișcării obiectelor urmărite are des o formă mixtă, în timp continuu t pentru vectorul de stare și timp discret pentru vectorul de observație:

$$\dot{x}(t) = f(x(t), u(t), t) + w(t) \quad (4.3)$$

$$z_k = h_k(x_k) + v_k \quad (4.4)$$

Modelele de mișcare ale țintelor punctiforme necesită anumite simplificări și aproximații ale parametrilor necunoscuți, în special utilizarea ipotezei că vectorul de control reprezintă un proces aleatoriu cu proprietăți specifice și folosirea de traiectorii tipice ale țintelor, cu parametrii traiectoriilor selectați în mod adecvat.

În mod uzual, mișcările țintelor sunt clasificate în două categorii: mișcări propulsate și nepropulsate. Mișcarea nepropulsată este una liniară, având o viteză constantă în sistemul inerțial de referință, denumită uneori și mișcare uniformă. Toate celelalte tipuri de mișcări fac parte din categoria mișcărilor propulsate.

4.1.1 Modele de mișcare uniformă

În cazul unui obiect punctiform, mișcarea sa uniformă este descrisă prin ecuația vectorială $\dot{x}(t) = 0$, unde $x = [x, y, z, v_x, v_y, z]^T$ este vectorul transpus de stare, conținând coordonatele de poziție și de viteză ale unui punct în sistemul de referință cartezian. De remarcat este faptul că în direcția z , viteza este tratată diferit, deoarece mișcarea uniformă este presupusă a avea loc exclusiv în planul orizontal $x - y$. În practică, această ecuație ideală este de obicei extinsă în așa fel încât și $w(t) = 0$, unde $w(t)$ este zgomot alb cu un efect neglijabil asupra vectorului de stare. Acesta reprezintă erorile de modelare imprevizibile datorate de exemplu turbulențelor sau rafalelor de vânt.

Modelul de mișcare uniformă în timp discret [37] este reprezentat de:

$$x_{k+1} = \text{diag}[F_2, F_2, 1]x_k + w_k \quad (4.3)$$

$$\text{cov}(w_k) = \text{diag}\left[\frac{S_x}{T} Q_2, \frac{S_y}{T} Q_2, \frac{S_z}{T}\right] \quad (4.4)$$

$$\text{unde } F_2 = \begin{bmatrix} 1 & T \\ 0 & 1 \end{bmatrix}, \quad Q_2 = \begin{bmatrix} T^4/3 & T^3/2 \\ T^3/2 & T^2 \end{bmatrix} \quad (4.5)$$

iar $w(t) = [w_x(t), w_y(t), w_z(t)]^T$ reprezintă un zgomot alb în timp continuu, corespunzător procesului de mișcare, având valori vectoriale și densitatea spectrală de putere dată de matricea $\text{diag}[S_x, S_y, S_z]$. Covarianța zgomotului este dată de ecuația (4.4), cu T fiind pasul de eșantionare. Notăția $A = \text{diag}[A_1, A_2, \dots, A_n]$ este utilizată pentru matricea bloc diagonală A , având matricile A_i ordonate pe diagonala principală și în rest elementele fiind zero, unde A_i și A nu sunt neapărat matrici pătratice.

Ecuatiile de mai sus modelează în timp discret mișcări cu viteză constantă (CV) sau mai exact mișcări cu viteză cvasi-constantă. Ecuația (4.3) reprezintă de fapt o mișcare cu „acelerație albă”, deoarece accelerațiile de-a lungul direcțiilor x și y sunt prezente, fiind însă foarte mici și cauzate de zgomotului alb.

Stimulul u de control al obiectului urmărit este considerat ca fiind nul, deși în realitate acesta poate exista sub forma unei propulsii moderate, necesare pentru a

echilibra eventuale influențe negative, permițând astfel menținerea mișcării uniforme. Includerea de componente adiționale în vectorul de stare, spre exemplu accelerațiile $[a_x, a_y, a_z]^T$, nu este necesară deoarece ar degrada inutil performanța algoritmilor de urmărire.

4.1.2 Modele de mișcare propulsată

În cazul unei ținte propulsate, stimulul de control al mișcării este de natură deterministă și de regulă necunoscut sistemelor de urmărire. Metode de *estimare a stimulului de control* [38] se concentrează pe modelarea deterministă a vectorului de control, pe baza datelor colectate în timpul procesului de urmărire. Din cauza faptului că dinamica sa este necunoscută, acest stimul de control este adesea presupus a fi cvasi-staționar și este tratat ca un parametru invariant într-un anumit interval relativ scurt de timp. Principala dificultate constă în stabilirea nivelurilor stimulului și a momentelor la care acestea se modifică.

O metodă alternativă, mult mai răspândită decât modelarea deterministă de mai sus, este modelarea bazată pe ipoteza că stimulul de control este un *proces aleatoriu*. Modelele din această categorie propuse în literatură pot fi grupate după cum urmează:

- Modele *de zgomot alb*: stimulul de control este modelat ca zgomot alb. Acestea includ modele cu viteză constantă, accelerație constantă și modele polinomiale.
- Modele *de proces Markov*: stimulul de control este modelat ca și un proces Markov, care prezintă o autocorelație temporală. Acestea includ cunoscutul model Singer, dar și un set suplimentar de variante.
- Modele *de proces semi-Markov cu salt*: stimulul de control este modelat ca și un proces semi-Markov cu salt de accelerație.

Majoritatea mișcărilor reale prezintă corelații între valorile coordonatelor lor în spațiul de referință. Pentru simplificare însă, modelele de mișcare propulsată presupun de regulă că aceste corelații sunt slabe și pot fi neglijate. Acest lucru este în special valabil în cazul modelării stimulului de control u ca și proces aleatoriu. În consecință, se va considera în continuare o singură direcție generică de deplasare. Fie x , \dot{x} și \ddot{x} poziția, viteza respectiv accelerația unui obiect-țintă de-a lungul unei direcții generice. Vectorul de stare $x = [x, \dot{x}, \ddot{x}]^T$ este și el considerat de-a lungul unei singure direcții generice.

Modelele prezentate în continuare diferă, în funcție de cum este definită accelerația sa în spațiul de stări, $a(t)$:

$$\ddot{x}(t) = a(t) \quad (4.6)$$

Cel mai simplu model al unei mișcări propulsate este reprezentat de modelarea accelerației ca fiind un *zgomot alb* [37]. Diferența față de modelul unei mișcări fără propulsie constă exclusiv în intensitatea zgomotului. Zgomotul alb utilizat pentru modelarea stimulului de control u are o intensitate mult mai mare decât cea utilizată într-un model fără propulsie. O manevră, respectiv un stimul de control, au ca scop îndeplinirea unei anumite sarcini și, prin urmare, sunt rareori independente în timp. Principalul avantaj al acestui model este simplitatea sa. El poate fi folosit atunci când stimulul este destul de mic sau aleatoriu. De asemenea, el este utilizat în anumite tehnici de urmărire pentru ajustarea nivelului de zgomot.

Al doilea model ca și complexitate este reprezentat de modelarea funcției de accelerație a unei ținte ca fiind un *proces Wiener* [37]. Accelerația este considerată fie un proces Wiener ori, mai general, un proces cu variații independente. Modelul este denumit și model cu accelerație constantă (CA) sau mai exact model cu accelerație cvasi-constantă. Derivata accelerației $\dot{a}(t) = w(t)$ este considerată a fi zgomot alb cu densitate spectrală de putere S_w . Ipoteza modelului CA că variația accelerației $\Delta a_{k+1} = a_{k+1} - a_k$ este independentă în intervale diferite de eșantionare nu este justificabilă în situații reale, ea fiind însă utilă datorită simplității și a manevrabilității sale matematice. Reprezentarea matematică în spațiul de stări este:

$$x_{k+1} = F_3 x_k + w_k \quad (4.7)$$

$$\text{cov}(w_k) = S_w Q_3 \quad (4.8)$$

$$\text{unde } F_3 = \begin{bmatrix} 1 & T & T^2/2 \\ 0 & 1 & T \\ 0 & 0 & 1 \end{bmatrix}, \quad Q_3 = \begin{bmatrix} T^5/20 & T^4/8 & T^3/6 \\ T^4/8 & T^3/3 & T^2/2 \\ T^3/6 & T^2/2 & T \end{bmatrix} \quad (4.9)$$

În teoria probabilităților, o variabilă aleatorie este utilizată pentru a reprezenta o valoare necunoscută, invariantă în timp. O valoare necunoscută care variază în timp este modelată printr-un proces stohastic sau aleatoriu. Din punctul de vedere al proprietăților temporale, zgomotul alb constituie cea mai simplă categorie de procese stohastice. A doua categorie ca și complexitate este dată de procesele cu variații independente, reprezentate de procesele Wiener, și suplimentar de *procesele Markov*. Acestea includ procesele Wiener și zgomotul alb ca și cazuri particulare. Zgomotul alb poate fi considerat ca fiind izolat în timp, deoarece valoarea sa la un moment dat este independentă de valoarea avută în oricare alt moment. În schimb, procesele Markov pot fi considerate ca fiind locale în timp, deoarece valorile instantanee ale acestora depind doar de valorile avute în momentele de timp imediat învecinate. În consecință, atunci când modelul de zgomot alb nu este suficient de bun, este firesc să se ia în considerare un model de proces Markov.

Modelul de accelerație *Singer* [39] presupune că accelerația țintei $a(t)$ este un proces Markov staționar de ordinul întâi cu valoare medie nulă, având funcția de autocorelație dată de relația $R_a(\tau) = E[a(t+\tau)a(t)] = \sigma^2 e^{-\alpha\tau}$.

Astfel, $a(t)$ reprezintă procesul de stare a unui sistem liniar, invariant în timp:

$$\dot{a}(t) = -\alpha a(t) + w(t), \quad \alpha > 0 \quad (4.10)$$

unde $w(t)$ este un zgomot alb cu valoare medie nulă și densitate de putere spectrală constantă $S_w = 2\alpha\sigma^2$.

Forma discretă a modelului de accelerație Singer este:

$$a_{k+1} = e^{-\alpha T} a_k + w_k^\alpha \quad (4.11)$$

unde w_k^α este o serie corespunzătoare unui zgomot alb cu valoare medie nulă și varianță $\sigma^2(1 - e^{-2\alpha T})$. Reprezentarea matematică a modelului de accelerație Singer în spațiul de stări este:

$$x_{k+1} = F_\alpha x_k + w_k \quad (4.12)$$

$$\text{unde } F_\alpha = \begin{bmatrix} 1 & T & (\alpha T - 1 + e^{-\alpha T})/\alpha^2 \\ 0 & 1 & (1 - e^{-\alpha T})/\alpha \\ 0 & 0 & e^{-\alpha T} \end{bmatrix} \quad (4.13)$$

Funcția de covarianță a zgomotului w_k depinde de α și T și forma ei completă poate fi găsită în sursa bibliografică [39]. Rezultatele modelului Singer depind de valorile parametrilor α și σ^2 [40]. Parametrul $\alpha = 1/\tau$ este inversa timpului de manevră τ și este deci dependent de durata stimulului de propulsie. În cazul unui viraj făcut de un avion, timpul de manevră τ este aproximativ 60s, în cazul unui autoturism el ia valori între 10 și 20s. Pe măsură ce τ crește și implicit αT scade, modelul Singer se reduce la modelul CA. Pe de altă parte, pe măsură ce timpul de manevră scade (adică αT crește), modelul Singer se reduce la modelul CV. În acest caz, accelerația devine zgomot alb. Prin urmare, pentru scenariii cu $0 < \alpha T < \infty$, modelul Singer corespunde unei mișcări situate între cele două situații, mișcarea cu viteză cvasi-constantă și mișcarea cu accelerația cvasi-constantă.

Manevre obișnuite de mișcare a unei ținte, de exemplu un viraj, au adesea o viteză și o rată de viraj aproximativ constante într-un anumit interval de timp de observație. Fie a_x și a_y componentele accelerației a de-a lungul direcțiilor x și y , respectiv $a = [a_x, a_y]^T$, v viteza de deplasare constantă, $\phi(t)$ unghiul de direcție și $\omega = \dot{\phi}$ rata constantă de viraj. În scenariul teoretic în care ω și ϕ sunt variabile aleatoare cu valori medii nule, distribuții simetrice și sunt reciproc independente, funcția de autocorelație a lui a_x este dată de ecuația 4.14 [41]. În mod similar se poate determina și autocorelația pentru a_y . Autocorelația temporală a unui semnal aleatoriu staționar este independentă de alegerea originii timpului, deci parametrii statistici ai semnalului aleatoriu sunt invarianți la translația în timp. Media sa nu depinde de timp iar funcția sa de autocorelație depinde numai de diferența între momentele de timp considerate. După cum se poate observa, accelerația longitudinală are o funcție de autocorelație dependentă de timpul de observație t , deci nu este un semnal staționar:

$$R(t + \tau, t) = \frac{1}{2} v^2 \times E[\omega^2 \{ \cos \omega \tau (1 - \cos 2\phi(t)) + \sin \omega \tau \sin 2\phi(t) \}] e^{-\alpha \tau} = \sigma^2(t, \tau) e^{-\alpha \tau} \quad (4.14)$$

Diferența majoră dintre acest *model Markov pentru mișcări cu rată constantă de viraj* și modelul Singer prezentat anterior este că σ^2 pentru accelerația a_x depinde și de momentul de timp t în care începe observarea procesului statistic. Pentru a obține un model cu invarianța în timp este necesară alegerea acelor distribuții statistice ale unghiului de direcție ϕ pentru care $R(t + \tau, t) = R(\tau)$. Distribuția uniformă a lui ϕ în intervalul $(-\pi, \pi]$ este un astfel de exemplu. Spectrul de putere $S(s)$ al accelerației poate fi aproximat cu funcția rațională de ordinul doi [41]:

$$S(s) = H(s)H(-s), \text{ cu } H(s) = \frac{\beta_1 s + \beta_2}{s^2 + \alpha_1 s + \alpha_2}, \quad (4.15)$$

ecuația de stare pentru $x = [x, \dot{x}, \ddot{x}, d_x]^T$ și considerând zgomotul $w_x(t)$ alb și cu densitate spectrală de putere unitară este:

$$\dot{x}(t) = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 0 & -\alpha_2 & -\alpha_1 \end{bmatrix} x(t) + \begin{bmatrix} 0 \\ 0 \\ \beta_1 \\ \beta_2 - \alpha_1 \beta_1 \end{bmatrix} w_x(t) \quad (4.16)$$

Modelul Singer aproximează accelerația unei ținte ca și un proces statistic Markov în timp continuu și cu medie zero. În realitate acest lucru este rar întâlnit, însă multe mișcări ale țintelor de interes au accelerații cu valori medii diferite de zero, dar care pot fi considerate constante pe anumite intervale de timp. Dificultatea care apare constă în faptul că nici intervalele de timp cu accelerație constantă și nici nivelurile de accelerație pe durata acestor intervale nu sunt cunoscute de către algoritmul de urmărire.

Unul dintre cele mai simple procese aleatoare cu stări constante pe intervale este așa-numitul *proces semi-Markov cu salt*. Stările unui proces semi-Markov depind de duratele intervalelor de timp în care sistemul persistă în stările anterioare, denumite timpi de sejur. Starea actuală depinde nu doar de starea anterioară ca și în cazul procesului Markov, ci și de timpul de ședere al sistemului, în cazul nostru a țintei, în acea stare și în stările precedente [42]. Un model uzual, prezentat pe larg în [43] consideră stimulul de control $u(t)$, egal cu valoarea medie nenulă a accelerației, ca fiind un proces statistic semi-Markov cu salt și cu număr finit de stări posibile. Stimulul de control $u(t_k)$ poate lua la un anumit moment de timp una din valorile discrete și cunoscute ale accelerației medii $\bar{a}_1, \bar{a}_2, \dots, \bar{a}_n$. Probabilitățile de tranziție între stări și distribuțiile de probabilitate ale timpilor de sejur sunt de asemenea cunoscute.

Pentru a simplifica modelul matematic, distribuțiile timpilor de sejur sunt considerate ca fiind funcții exponențiale. Distribuția exponențială (vezi Figura 38) ca și caz particular al distribuției gamma cu $\alpha = 1$, înseamnă de fapt, că probabilitatea de sejur foarte scurt într-o anumită stare este maximă, ea scăzând exponențial, deci foarte rapid, cu creșterea timpului de sejur. În acest caz, starea actuală nu mai depinde de timpul de sejur în starea anterioară, ci doar de starea anterioară, reducând modelul procesului statistic la unul Markov.

Acest model reprezintă accelerația $a(t)$ ca și o combinație între modelul semi-Markov cu salt și modelul Singer prezentat mai sus:

$$a(t) = -\beta v(t) + u(t) + \tilde{a}(t) \tag{4.15}$$

unde $\tilde{a}(t)$ este accelerația Singer din ecuația 4.10, v este viteza obiectului de interes, $u(t)$ este valoarea medie a accelerației, iar β este un coeficient de frână. Pentru stările $x = [x, \dot{x}, \ddot{x}]^T$, reprezentarea matematică în spațiul de stări a modelului de accelerație semi-Markov cu salt este:

$$\dot{x}(t) = \begin{bmatrix} 1 & 1 & 0 \\ 0 & -\beta & 1 \\ 0 & 0 & -\alpha \end{bmatrix} x(t) + \begin{bmatrix} 0 \\ 1 \\ 0 \end{bmatrix} u(t) + \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} w(t) \tag{4.16}$$




Figura 38: Distribuții gamma ale probabilităților de sejur în procese semi-Markov

Stimulul de control necunoscut $u(t)$ este aproximat cu o sumă ponderată a nivelurilor cuantizate ale accelerației: $\hat{u}(t) = \sum_{i=1}^n \bar{a}_i P\{u(t) = a_i | z(s), s \leq t\}$, unde ponderile sunt date de probabilitatea aposteriori a fiecărui nivel ca acesta să fie cel în care se face tranziția la momentul t . Aceste probabilități aposteriori conțin informațiile provenite din toate observațiile $z(s)$ făcute până la momentul t , și consideră de asemenea probabilitățile de tranziție între stări și distribuțiile gamma de probabilitate ale timpilor de sejur.

4.1.3 Modele de mișcare planară

Majoritatea mișcărilor planare ale țintelor sunt de regulă mișcări bazate pe diferite viraje. Spre deosebire de mișcările prezentate mai sus, care au ca modele matematice procese aleatorii, modelele de mișcare în plan pot fi reprezentate pe baza parametrilor cinematici ai țintelor.

Modelele cinematice utilizate de sistemele de urmărire a țintelor în mișcare sunt derivate din următorul set generic de ecuații, ce descriu mișcarea unui obiect pe o traiectorie curbă (vezi Figura 39):

$$\begin{aligned} \dot{x}(t) &= v(t) \cos \phi(t) \\ \dot{y}(t) &= v(t) \sin \phi(t) \\ \dot{v}(t) &= a_t(t) \\ \dot{\phi}(t) &= a_n(t)/v(t) \end{aligned} \quad (4.17)$$

în care (x, y) , v și ϕ sunt poziția ținte în sistemul cartezian de coordonate, viteza de deplasare și respectiv, unghiul de direcție al acesteia, iar a_t respectiv a_n sunt componentele tangențiale și normale ale accelerației în plan orizontal.




Figura 39: Traiectoria unei ținte în coordonate 2D, sursă [36]

Acest model este unul general, fiind valabil pentru obiecte de interes având accelerații atât în direcția de deplasare, cât și în direcția perpendiculară pe direcția de deplasare. Modelul poate fi simplificat în următoarele cazuri speciale:

- $a_n = 0$, $a_t = 0$, mișcare liniară, cu viteză constantă (CV)
- $a_n = 0$, $a_t \neq 0$, mișcare liniară, accelerată (și constantă, dacă a_t este constantă, CA)

- $a_n \neq 0$, $a_t = 0$, mișcare circulară, cu viteză constantă (și cu rată de viraj constantă dacă a_n este constantă, CT)

Modelul CT cu rată de viraj cunoscută este valabil pentru obiecte care se deplasează cu viteză constantă și rată unghiulară de viraj constantă ω . În ipoteza că vectorul de stare are patru componente $x = [x, \dot{x}, y, \dot{y}]^T$, mișcarea circulară este descrisă analitic de următoarele ecuații:

$$\dot{x}(t) = \begin{bmatrix} \dot{x}(t) \\ -\omega\dot{y}(t) \\ \dot{y}(t) \\ \omega\dot{x}(t) \end{bmatrix} + Bw(t) = A(\omega)x(t) + Bw(t) \quad (4.18)$$

$$A(\omega) = \begin{bmatrix} 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & -\omega \\ 0 & 0 & 0 & 1 \\ 0 & \omega & 0 & 0 \end{bmatrix}, \quad B = \begin{bmatrix} 0 & 0 \\ 1 & 0 \\ 0 & 0 \\ 0 & 1 \end{bmatrix}$$

unde zgomotul alb $w = [w_x, w_y]^T$ are densitatea spectrală de putere $\text{diag}[S_w, S_w]$. Acest model CT este unul liniar cu ω cunoscută.

Reprezentarea echivalentă a acestui model în timp discret este [44]:

$$x_{k+1} = F_{ct}(\omega)x_k + w_k$$

$$F_{ct}(\omega) = \begin{bmatrix} 1 & \frac{\sin\omega T}{\omega} & 0 & -\frac{1 - \cos\omega T}{\omega} \\ 0 & \cos\omega T & 0 & -\frac{\sin\omega T}{\omega} \\ 0 & \frac{1 - \cos\omega T}{\omega} & 1 & \frac{\sin\omega T}{\omega} \\ 0 & \frac{\sin\omega T}{\omega} & 0 & \cos\omega T \end{bmatrix} \quad (4.19)$$

unde covarianța zgomotului este:

$$Q = \text{cov}(w_k) = \begin{bmatrix} \frac{2(\omega T - \sin\omega T)}{\omega^3} & \frac{1 - \cos\omega T}{\omega^2} & 0 & \frac{\omega T - \sin\omega T}{\omega^2} \\ \frac{1 - \cos\omega T}{\omega^2} & T & -\frac{\omega T - \sin\omega T}{\omega^2} & 0 \\ 0 & -\frac{\omega T - \sin\omega T}{\omega^2} & \frac{2(\omega T - \sin\omega T)}{\omega^3} & \frac{1 - \cos\omega T}{\omega^2} \\ \frac{\omega T - \sin\omega T}{\omega^2} & 0 & \frac{1 - \cos\omega T}{\omega^2} & T \end{bmatrix} \quad (4.20)$$

O aproximare a termenului lipsit de zgomot din ecuația (4.19) este dată de formula [45], [46]:

$$F_{ct}(\omega)x_k \approx \begin{bmatrix} 1 & T & 0 & -\omega T^2/2 \\ 0 & 1 - (\omega T)^2/2 & 0 & -\omega T \\ 0 & \omega T^2/2 & 1 & T \\ 0 & \omega T & 0 & 1 - (\omega T)^2/2 \end{bmatrix} x_k \quad (4.21)$$

$$= \begin{bmatrix} x + (\dot{x} - \dot{y}\omega T/2)T \\ \dot{x} - \dot{y}\omega T - \dot{x}(\omega T)^2/2 \\ y + (\dot{y} + \dot{x}\omega T/2)T \\ \dot{y} + \dot{x}\omega T - \dot{y}(\omega T)^2/2 \end{bmatrix}$$

fiind o funcție polinomială de ordinul 2, dependentă de ω . Ecuația de mai sus reprezintă o formă simplificată, dar mai puțin exactă a modelului CT de bază. Aceasta are o importanță deosebită în cazul algoritmilor de tracking neliniari, cum ar fi de exemplu filtrul Kalman extins (EKF) care consideră vectorul de stare având în componența sa rata de viraj necunoscută. Aproximarea este valabilă doar în situații în care $\omega T \approx 0$, deci cu intervale de scanare și viteze de rotație relativ mici.

În cazurile rar întâlnite în practică în care rata de viraj este cunoscută a priori, modelul de mai sus are rezultate de tracking remarcabile. Necesitatea de a cunoaște în prealabil rata de viraj împiedică din păcate utilizarea directă a acestui model în majoritatea situațiilor întâlnite în aplicațiile practice. O soluție utilizată frecvent constă în aproximarea lui ω prin mai multe valori cunoscute, constante pe intervale de timp. Această metodă reduce efectele negative date de necunoașterea ratei de viraj și oferă avantajul considerabil al reprezentării modelului dinamic corespunzător sub o formă relativ simplă și liniară. Mulțimea de valori consecutive ale ratei de viraj $\langle \omega_k \rangle$ este modelată printr-un lanț Markov (sau semi-Markov) cu valori din mulțimea $\{\omega_1, \omega_2, \dots, \omega_n\}$ și având probabilitățile de tranziție de la o rată la alta dată de $P\{\omega_k = \omega_i | \omega_{k-1} = \omega_j\}, i, j = 1, \dots, n$. Această metodă este foarte uzuală în aplicații de control al traficului aerian [44], [45], [46].

Modelul CT cu rată de viraj necunoscută este similar cu cel prezentat mai sus, însă conține în vectorul său de stare și rata de viraj ce urmează a fi determinată. Ecuațiile de mișcare sunt aceleași ca și cele prezentate în (4.18) pentru timpul continuu, și respectiv în (4.19) pentru timpul discret. În plus mai apare o ecuație suplimentară pentru ω . Cele mai frecvent utilizate modele sunt procesul Wiener:

$$\begin{aligned} \dot{\omega}(t) &= w_\omega(t), \text{ în timp continuu} \\ \omega_{k+1} &= \omega_k + w_{\omega,k}, \text{ în timp discret} \end{aligned} \quad (4.22)$$

și procesul Markov de ordinul întâi:

$$\begin{aligned} \dot{\omega}(t) &= -\frac{1}{\tau_\omega} \omega(t) + w_\omega(t), \text{ în timp continuu} \\ \omega_{k+1} &= e^{-T/\tau_\omega} \omega_k + w_{\omega,k}, \text{ în timp discret} \end{aligned} \quad (4.23)$$

unde τ_ω este constanta de timp de corelație a ratei de viraj și w este zgomot alb cu valoare medie nulă.

Modelul de mișcare în timp continuu are o acuratețe mai mare decât cel în timp discret. Datorită răspândirii foarte mari a procesoarelor digitale de semnal, modelele dinamice în timp discret sunt însă cele mai frecvent utilizate. În cazul în care modelul dinamic în timp continuu este neliniar, ca și în cazul modelului CT cu rată de viraj necunoscută, există două modalități generice de aproximare a acestuia în timp discret. Prima modalitate este liniarizarea locală a ecuației neliniare de stare, urmată de discretizarea ecuației diferențiale liniarizate. Această metodă este foarte uzuală datorită gradului său redus de complexitate. Alternativ, se poate discretiza întâi ecuația de stare neliniară și apoi liniariza local ecuația cu diferențe finite. Cele două metode sunt denumite liniarizare discretizată respectiv discretizare liniarizată și sunt descrise în [47] și [48] respectiv [49].

Pentru modelele de mișcare cu viraje, alegerea vectorului de stare nu este simplă. În principiu, există două categorii diferite de vectori de stare care se deosebesc între ele prin modul de reprezentare a vectorului de viteză, fie în coordonate carteziane, fie în coordonate polare.

Modelele CT cu viteză în coordonate carteziene au vectorul de stare $x = [x, \dot{x}, y, \dot{y}, \omega]^T$, respectiv vectorul de viteză $[\dot{x}, \dot{y}]^T$. În consecință, ecuația de stare în timp discret are forma [44]:

$$x_{k+1} = \begin{bmatrix} F_{ct}(\omega^*) & 0 \\ 0 & \beta \end{bmatrix} x_k + \text{diag}[G_2, G_2, 1] w_k; \quad G_2 = \begin{bmatrix} T^2/2 \\ T \end{bmatrix} \quad (4.24)$$

unde $\beta = e^{-\alpha T}$, $\omega^* = \omega_k, \omega_{k+1}$ sau $\bar{\omega}$, iar $w_k = [w_x, w_y, w_\omega]^T$ este zgomot alb cu valoare medie nulă și parametri statistici, corespunzători coordonatelor x și y , respectiv ratei de viraj. Acest model este utilizat în analizele efectuate în subcapitolul 5.9.

În cazul modelelor CT cu vectorul de viteză reprezentat în coordonate polare, acesta are forma $[v, \phi]^T$ având componentele $v = \sqrt{\dot{x}^2 + \dot{y}^2}$ și unghiul de direcție $\phi = \arctg(\dot{y}/\dot{x})$. Vectorul de stare corespunzător este $x = [x, y, v, \phi, \omega]^T$. Ecuația diferențială de stare este:

$$\dot{x}(t) = \begin{bmatrix} v \cos \phi \\ v \sin \phi \\ 0 \\ \omega \\ 0 \end{bmatrix} + w(t) \quad (4.25)$$

După liniarizarea inițială urmată de discretizare se obține ecuația echivalentă în timp discret [50]:

$$x_{k+1} = \begin{bmatrix} x + (2/\omega)v \sin(\omega T/2) \cos(\phi + \omega T/2) \\ y + (2/\omega)v \sin(\omega T/2) \sin(\phi + \omega T/2) \\ v \\ \phi + \omega T \\ \omega \end{bmatrix}_k + w_k \quad (4.26)$$

unde w_k este zgomotul având covarianța:

$$Q = \text{diag} \left[\begin{bmatrix} 0 & 0 \\ 0 & 0 \end{bmatrix}, T^2 \sigma_i^2, \begin{bmatrix} T^3 \sigma_\omega^2/3 & T^2 \sigma_\omega^2/2 \\ T^2 \sigma_\omega^2/2 & T^2 \sigma_\omega^2 \end{bmatrix} \right] \quad (4.27)$$

Acest model a fost utilizat cu succes în algoritmi pentru urmărirea țintelor aeronautice în aplicații militare [51], [52].

4.2 Filtrele Kalman

Pentru modele liniare de observație și de mișcare și în cazul zgomotului de proces, respectiv de observație de tip gaussian și reciproc independent (i.i.d.), filtrul optimal de urmărire a țintelor este filtrul Kalman [19], [53], [54], [55] și [56]. Funcționarea acestuia constă din două etape, una de predicție, având la bază modelul dinamic al obiectelor urmărite și observațiile anterioare, iar cea de-a doua de corecție, etapă ce ia în considerare observațiile curente, prelevate de către senzorul de referință.

Pentru un model liniar de observație, este valabilă ecuația:

$$z_k = Hx_k + v_k \quad (4.28)$$

unde $z_k = [x^m, y^m]_k^T$ reprezintă componentele măsurătorii k , $H = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$ este matricea de observare, iar $v_k = [v_x, v_y]_k^T$ este zgomotul de observare, cu parametri statistici cunoscuți. Zgomotul v_k este presupus a fi gaussian, cu medie nulă și cu matricea de covarianță diagonală și cunoscută $R = \begin{bmatrix} \sigma_x^2 & 0 \\ 0 & \sigma_y^2 \end{bmatrix}$.

Ecuția de predicție a algoritmului Kalman de urmărire a țintelor calculează starea presupusă x_{k+1} a unei ținte la momentul actual, considerând observațiile prelevate până la momentul anterior:

$$\hat{x}_{k+1|k} = F\hat{x}_{k|k} \quad (4.29)$$

Ecuția corespunzătoare etapei de corecție prezintă starea estimată a ținteii la momentul actual $k+1$, luând în considerare toate observațiile făcute până la momentul curent, deci cele cumulate până în momentul anterior plus observația z_{k+1} prelevată la momentul actual:

$$\hat{x}_{k+1|k+1} = \hat{x}_{k+1|k} + K_{k+1}(z_{k+1} - H\hat{x}_{k+1|k}) \quad (4.30)$$

Covarianța stării în etapa de predicție este:

$$P_{k+1|k} = Q + FP_{k|k}F^T \quad (4.31)$$

Covarianța stării în etapa de corecție este:

$$P_{k+1|k+1} = P_{k+1|k} - K_{k+1}S_{k+1}K_{k+1}^T \quad (4.32)$$

unde S_{k+1} reprezintă covarianța măsurătorii actuale:

$$S_{k+1} = R - HP_{k+1|k}H^T \quad (4.33)$$

și K_{k+1} este factorul de amplificare (câștigul) al filtrului Kalman:

$$K_{k+1} = P_{k+1|k}H^T S_{k+1}^{-1} \quad (4.34)$$

Filtrul Kalman este unul linear, iar matricile $P_{k+1|k}$, $P_{k+1|k+1}$, $S_{k+1|k}$ și K_{k+1} pot fi calculate offline. Etapele de procesare ale filtrului Kalman sunt prezentate în Figura 40.




Figura 40: Schema bloc a unui filtru Kalman

De regulă însă, radarele îmbarcate pe automobile nu furnizează măsurători cu caracteristici liniare ale țintelor cu reprezentare a vectorului de stare în coordonate carteziane, ci măsurători în domeniul distanță r și unghi de direcție ϕ cu măsurători în domeniul distanță r și viteză \dot{r} . Modelul de observație corespunzător este:

$$z_k = h(x_k) + v_k \quad (4.35)$$

unde $z_k = [r^m, \phi^m, \dot{r}^m]^T$, $h(x_k) = [r, \phi, \dot{r}]^T$ și zgomotul de observație $v_k = [v_r, v_\phi, v_{\dot{r}}]^T$. Similar cu modelul dinamic în coordonate carteziane, și în cazul mișcărilor cu reprezentare în coordonate polare, zgomotul este considerat a fi gaussian, cu medie nulă și matrice de covarianță diagonală $R = \text{diag}\{\sigma_r^2, \sigma_\phi^2, \sigma_{\dot{r}}^2\}$.

Se poate observa că:

$$\begin{aligned} r_k = h_r(x_k) &= \sqrt{x_k^2 + y_k^2}, \phi_k = h_\phi(x_k) = \arctg(y_k/x_k) \\ \text{și } \dot{r}_k = h_{\dot{r}}(x_k) &= \frac{x_k \dot{x}_k + y_k \dot{y}_k}{\sqrt{x_k^2 + y_k^2}} \end{aligned} \quad (4.35)$$

Deoarece măsurătorile au o dependență neliniară de vectorul de stare, filtrul Kalman nu mai poate fi utilizat. În aceste cazuri, este aplicat de regulă filtrul Kalman extins [37], [57] (extended Kalman filter, EKF). Filtrul EKF realizează o liniarizare locală a funcțiilor neliniare $h(x_k)$, astfel încât

$$H_k = [\nabla_{x_k} h^T(x_k)]^T \Big|_{x_k = \hat{x}_{k|k-1}} \quad (4.36)$$

unde $[\nabla_{x_k} h^T(x_k)]^T$ este Jacobian-ul lui $h(x_k)$.

Cele două ecuații corespunzătoare filtrului EKF sunt ecuația de predicție:

$$\hat{x}_{k+1|k} = F \hat{x}_{k|k} \quad (4.37)$$

și respectiv ecuația de corecție:

$$\hat{x}_{k+1|k+1} = \hat{x}_{k+1|k} + K_{k+1}(z_{k+1} - h_{k+1} \hat{x}_{k+1|k}) \quad (4.38)$$

Covarianța stării în etapa de predicție este $P_{k+1|k} = Q + F P_{k|k} F^T$. După corecție $P_{k+1|k+1} = P_{k+1|k} - K_{k+1} S_{k+1} K_{k+1}^T$, unde S_{k+1} este covarianța măsurătorii actuale, $S_{k+1} = R - H_{k+1} P_{k+1|k} H_{k+1}^T$, iar K_{k+1} este factorul de amplificare al filtrului Kalman extins, $K_{k+1} = P_{k+1|k} H_{k+1}^T S_{k+1}^{-1}$. Utilizarea Jacobian-ului lui $h(x_k)$, deci a aproximării de ordin întâi a lui $h(x_k)$, poate conduce la rezultate inconsistente în valorile matricei de covarianță S_{k+1} , ulterior la valori incorecte ale factorului de amplificare și în consecință ale ieșirii filtrului. Pentru a elimina aceste dezavantaje, se pot utiliza filtre cu reuniune de particule [58].

4.3 Algoritmi de urmărire a țintelor extinse

Algoritmii de urmărire concomitentă a mai multor ținte [59] au fost dezvoltați inițial pentru scenarii în care obiectele observate se află la distanțe mari față de punctul de observație, cum ar fi de exemplu supravegherea traficului aerian prin intermediul radarelor. În astfel de situații, există posibilitatea ca la un moment dat, anumite ținte să nu fie detectate de către sistemul de supraveghere, iar dacă sunt detectate, fiecare țintă ocupă maxim o celulă de rezoluție. Din acest punct de vedere, modelarea matematică a problemei dată de urmărirea concomitentă a mai multor ținte de dimensiuni reduse are la bază următoarele ipoteze:

- obiectele urmărite se mișcă necorelat, fără nici o interdependență,
- fiecare obiect poate fi reprezentat ca și un punct singular și
- fiecare obiect generează maxim un ecou radar pentru fiecare scanare.

Problema este complexă, datorită limitărilor cauzate de zgomotul sistemului de măsură, a detecțiilor ratate, a detecțiilor parazitare, a incertitudinii legate de sursa măsurătorilor și de numărul de ținte care variază în funcție de timp. Fenomenele care trebuie combătute sunt următoarele [60]:

- apariția țintelor fantomă, atunci când reflexiile parazitare sunt asociate în mod eronat unor obiecte reale,
- atribuirea mai multor ecouri diferite aceluiași obiect,
- goluri în cadrul traiectoriei unei ținte, cauzate de exemplu de obstrucționarea temporară a transmițătorului radar, sau de interferențe electromagnetice de intensitate ridicată,
- localizarea inexactă a țintelor datorită reflexiilor multiple, cauzate de exemplu de poziția de montare a senzorului radar din spatele barei de protecție a vehiculului,
- detecția întârziată în cazul apariției unei ținte noi în zona de acoperire și
- estimarea neadecvată a vitezei de deplasare a obiectului urmărit.

Evoluția tehnologică a radarelor și extinderea domeniilor de aplicație a acestora, de exemplu în industria autovehiculelor sau pentru roboți industriali, au condus la revizuirea ipotezelor menționate mai sus, în cazul în care obiectele pot ocupa mai mult decât o singură celulă de rezoluție a zonei de acoperire a radarului la un moment dat. În scenariile de urmărire a obiectelor extinse, obiectele de interes dau naștere unui număr variabil de măsurători, potențial zgomotoase din diferite surse punctuale distribuite spațial, denumite și puncte de reflexie. Forma obiectului urmărit este de obicei necunoscută și poate varia în timp. Obiectivul primar este reprezentat de determinarea recursivă a formei și parametrilor cinematici pentru fiecare țintă în parte. Datorită neliniarității problemei de estimare, chiar și urmărirea unui singur obiect extins devine extrem de complexă.

Obiectele de interes din lumea reală au întotdeauna dimensiuni extinse în spațiu. Acest lucru este valabil atât pentru obiectele relativ mari, cum ar fi nave, bărci, mașini, bicicliști, oameni sau animale, cât și pentru obiectele de dimensiuni relativ mici, cum ar fi celulele. Diferențele dintre algoritmi care urmăresc obiecte extinse, față de cei cu urmărire punctuală, se datorează performanțelor senzorului, în special a rezoluției acestuia, și nu proprietăților obiectelor, cum ar fi de exemplu mărimea acestora în spațiu. Dacă rezoluția, relativ la dimensiunea obiectelor, este suficient de bună, atunci o țintă poate ocupa mai multe celule de rezoluție din zona de acoperire a senzorului. Astfel, fiecare obiect urmărit poate genera mai multe ecouri per scanare. Cu alte cuvinte, în funcție de proprietățile senzorului, în special de rezoluția acestuia, vor fi considerate tipuri diferite de algoritmi de urmărire a obiectelor și, prin urmare, este necesar să se facă o diferențiere exactă între tipurile de probleme de urmărire a obiectelor:

- *Urmărirea obiectelor singulare:* fiecare obiect generează cel mult un ecou radar per scanare, adică ocupă o singură celulă de rezoluție la un moment dat.
- *Urmărirea obiectelor extinse:* fiecare obiect generează mai multe ecouri per scanare, iar detecțiile la receptor sunt grupate spațial în jurul țintelor. Un obiect ocupă mai multe celule de rezoluție la un moment dat.
- *Urmărirea obiectelor de grup:* fiecare obiect generează mai multe ecouri per scanare, iar măsurătorile sunt structurate spațial în jurul obiectului. Un obiect de grup este format din două sau mai multe sub-obiecte care participă la o mișcare comună. Mai mult, obiectele nu sunt urmărite individual, ci sunt tratate ca o singură entitate. Astfel, obiectul de grup ocupă mai multe celule

de rezoluție. Fiecare sub-obiect poate ocupa una sau mai multe celule de rezoluție.

- *Urmărirea țintelor cu ecouri propagate pe mai multe căi:* Fiecare obiect generează mai multe ecouri per scanare, datorită propagării pe mai multe căi a semnalului reflectat de țintă, de exemplu în linie aeriană directă, prin reflexii pe carosabil, sau prin reflexii laterale datorate altor mașini, copaci sau obstacole. În acest caz, detecțiile nu sunt centrate la receptor în jurul obiectului, provocând eventual erori suplimentare de măsură.

În cazul urmării obiectelor extinse, fiecare obiect este o entitate unică, de exemplu o mașină, un avion, un om sau un animal. Adesea ținta este considerată a fi un corp rigid cu toate că este validă și ipoteza unei ținte cu contur deformabil. În cazul urmării obiectelor de grup, fiecare țintă urmărită este în realitate o colecție de obiecte, care împărtășesc anumite dinamici comune, având însă o mișcare individuală în cadrul grupului. Într-un grup de pietoni, poate exista de exemplu o mișcare comună a grupului, dar fiecare pieton în parte își poate schimba poziția relativă în interiorul grupului.

Pentru modelarea formei obiectelor de interes, este util să se distingă niveluri diferite de complexitate (Figura 41), deoarece acestea implică aproximări și algoritmi diferiți:

- Cel mai simplu nivel de modelare este considerarea țintelor fără formă, adică evaluarea exclusivă a proprietăților de mișcare ale obiectului. Această abordare are cea mai mică complexitate de calcul, iar flexibilitatea de a urmări diferite tipuri de obiecte este mare. Deși este simplist în ceea ce privește forma obiectului, modelul este ușor de aplicat, având pe de altă parte un grad redus de acuratețe.
- Un nivel mai avansat de modelare constă în considerarea unei forme geometrice de bază specifice fiecărei ținte, cum ar fi de exemplu o elipsă, un triunghi sau un dreptunghi.
- Cea mai avansată abordare este de a construi un model, care să poată gestiona o varietate largă de forme și de reprezentări datorate aparițiilor diferite ale țintelor urmărite în funcție de orientarea lor în spațiu. Deși un astfel de model este mai general, el este de asemenea substanțial mai complex, din punct de vedere al capacității de calcul necesare.



Figura 41: Niveluri de complexitate în modelarea conturului unei ținte

Algoritmul de urmărire a obiectelor extinse utilizat în această lucrare constă din trei componente de bază: lista punctelor detectate în ultimele T cicluri de radar este recepționată de la procesorul de semnal brut, care are un transceiver performant și se calculează vectorul de mișcare al grupului \vec{v} . Ulterior se realizează segmentarea mișcării, prin asocierea fiecărui punct detectat ca aparținând unui obiect staționar, unui obiect compact în mișcare sau unei surse de zgomot. În cele din urmă, algoritmul de urmărire a obiectelor extinse prezentat în Figura 42 selectează punctele respectiv cele mai apropiate (C), cele mai depărtate în stânga (L) și cele mai depărtate în dreapta (R) corespunzătoare fiecărei ținte, folosind un filtru Kalman multidimensional și un model de predicție, bazat pe o formă dreptunghiulară a obiectului. Determinarea

64 Algoritmi de urmărire a țintelor extinse

precisă a conturului vehiculului, a orientării și a părților sale rotative cu ajutorul efectului micro-Doppler este foarte utilă în manevrele de parcare și în timpul deplasărilor în oraș. Pentru obiectele îndepărtate ($> 70\text{m}$), algoritmul revine la urmărirea unui singur punct reprezentativ per țintă [61], [62].

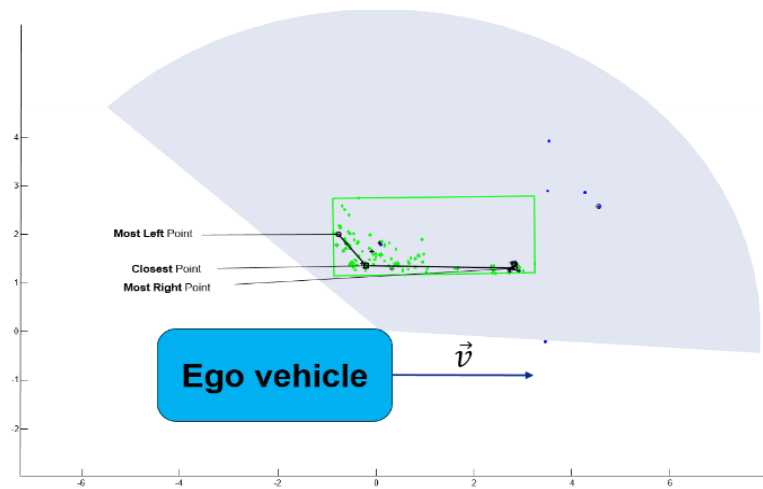


Figura 42: Urmărirea țintelor extinse caracterizate de câte trei puncte (CLR). Axele în [m].

5 EVALUAREA PERFORMANȚELOR ALGORITMILOR DE TRACKING

Acest capitol prezintă într-o formă actualizată și extinsă rezultatele experimentale publicate în lucrările proprii din [63], [64] și [65]. Algoritmii de urmărire a țintelor multiple [66] sunt folosiți frecvent în diverse aplicații industriale sau științifice, ca de exemplu în industria automotive [67], [68], [69], în biologie pentru studiul dinamicii celulelor, în domeniul aeronautic, în cadrul supravegherii video a magazinelor de retail sau în domeniul apărării. Problema centrală a acestor algoritmi este reprezentată de estimarea cât mai exactă a numărului de ținte din zona de acoperire și de localizarea corectă a acestor ținte în spațiul geometric al stărilor. În al doilea rând, algoritmi trebuie să atribuie în mod continuu, rapid și cu acuratețe fiecărui obiect detectat câte un obiect fizic, prezent în realitate. Pentru a putea evalua gradul de performanță al fiecărui algoritm în parte, este necesară măsurarea distanței dintre două mulțimi de traiectorii (Figura 43), una reprezentând traiectoriile reale ale țintelor o_i (linii continue), iar cealaltă reprezentând traiectoriile estimate de către senzorul radar h_i (linii punctate).




Figura 43: Urmărirea țintelor multiple

Pentru obiecte-țintă cu reprezentare extinsă (vezi subcapitolul 4.3) există un număr mare de indicatori ai gradului de eficacitate a algoritmilor de tracking. Aceste componente măsurabile ale gradului de eficiență [62], ca de exemplu liniaritatea în timp, acuratețea de detecție a traiectoriei, continuitatea, precizia de localizare sau numărul de traiectorii false (falsuri pozitive/alarme false), trebuie combinate în așa manieră încât să se obțină un număr cât mai redus de indicatori de performanță, care evidențiază toți parametrii relevanți pentru caracterizarea algoritmilor de tracking. Deseori, aceste componente sunt corelate și intransitive, ducând la concluzii greșite sau inadecvate dacă sunt considerate individual. De exemplu, un timp redus de inițializare a traiectoriilor țintelor noi apărute în câmpul de observație implică de regulă un număr ridicat de alarme false [70].

În urmă cu peste un secol, Hausdorff a introdus în [71] o metrică nouă pentru a determina distanța dintre două mulțimi de valori X respectiv Y . Această metrică nu ține cont însă de numărul de elemente ale celor două mulțimi considerate (Figura 44):

$$D_H(X, Y) = \max \left\{ \sup_{x \in X} \inf_{y \in Y} d(x, y), \sup_{y \in Y} \inf_{x \in X} d(x, y) \right\}.$$

Distanța Wasserstein [72] rezolvă parțial problema cardinalității, care apare atunci când numărul de elemente ale celor două mulțimi analizate este diferit. Metrica CLEAR (classification of events, activities, and relationships) [70] și ulterior metrica OSPA (optimal subpattern assignment) pentru filtre [73], respectiv algoritmi de tracking [74], au adus îmbunătățiri considerabile instrumentelor de evaluare a performanței sistemelor de urmărire a țintelor. Îmbunătățirile principale constau în rezolvarea problemelor cunoscute, legate de cardinalitatea mulțimilor și de confundarea între traiectorii și, de asemenea, în demonstrațiile matematice aduse, și anume că metricile noi prezintă proprietățile definitorii ale unei metrici: identitate, simetrie și respectarea inegalității triunghiului.

Publicații recente iau în considerare incertitudinea măsurătorilor în calculul OSPA, prin utilizarea distanței de bază Hellinger dintre două distribuții statistice [75], în timp ce în [76] este prezentată o generalizare a OSPA pentru mulțimi finite de valori aleatorii. Alte metrici aplicabile doar în cazul unor aplicații specifice sunt descrise în [77] și [78].




Figura 44: Metrica Hausdorff

5.1 Metrici CLEAR

Precizia și acuratețea sistemelor de urmărire a obiectelor multiple (MOT), introduse în cadrul metricilor CLEAR în [70], au rolul de a exprima într-un mod simplu și intuitiv nivelul de performanță al algoritmilor de tracking.

Precizia depinde de eroarea totală de localizare în spațiul de stări pentru perechile de obiecte reale asociate cu traiectorii estimate de către senzor. Spațiul stărilor poate include de exemplu coordonatele în spațiul geometric x, y, z , componentele de viteză v_x, v_y, v_z a țintelor și respectiv componentele lor de accelerație a_x, a_y, a_z . Eroarea de localizare d_i^t este acumulată pe parcursul ciclurilor anterioare t pentru toate dimensiunile spațiului de stări i , iar c_t reprezintă numărul total de comparații făcute, deci de diferențe calculate, până la momentul t . Precizia MOT

(notată în continuare cu MOTP) are unitatea de măsură corespunzătoare spațiului stărilor, de exemplu $[m]$, $[m/s]$ sau $[m/s^2]$ și este dată de formula:

$$MOTP = \frac{\sum_{i,t} d_i^t}{\sum_t c_t} \quad (5.1)$$

Pe de altă parte, acuratețea MOT (notată în continuare cu MOTA) este formată din trei componente, care corespund numărului de ținte ratate m_t , de falsuri pozitive/alarme false fp_t și respectiv numărului de confuzii mme_t . Numărul de traiectorii reale g_t este integrat pe parcursul numărului de iterații t . MOTA este o valoare adimensională, luând valori în intervalul $(-\infty, 1]$ și are forma:

$$MOTA = 1 - \frac{\sum_t (m_t + fp_t + mme_t)}{\sum_t g_t} \quad (5.2)$$

Țintele ratate și alarmele false influențează direct cardinalitatea mulțimilor de valori considerate. Un obiect nedetectat reduce numărul total de valori prezente în mulțimea de valori estimate. Alarmele false sunt obiecte inexistente în realitate, dar care sunt luate în considerare de către radar, datorită zgomotului sau a reflexiilor parazitare. Acestea duc la incrementarea eronată a numărului de valori din mulțimea de valori estimate. Un număr mic de erori de cardinalitate înseamnă deci o valoare MOTA aproape de maximul său 1. Pe de altă parte, în scenariile cu o singură țintă reală și multe detecții false, precizia instantanee devine puternic negativă.

Într-un scenariu cu ținte multiple, o confuzie apare atunci când un obiect detectat este asociat unui obiect real existent, dar diferit de cel care a generat ecoul detectat. Această situație apare des, atunci când obiectele reale se apropie foarte mult unele de altele, de exemplu, în cazul mai multor autovehicule care se mișcă într-o intersecție sau în cazul unei depășiri pe autostradă. De regulă, numărul de confuzii mme_t este mult mai mic (mai multe ordine de mărime) decât cel al numărului de falsuri pozitive sau de falsuri negative. Astfel efectul confuziilor devine invizibil în valoarea MOTA. De asemenea, durata confuziilor nu influențează deloc valoarea MOTA, deoarece nepotrivirile sunt numărate o singură dată, atunci când apar. Un algoritm care sesizează rapid confuzia făcută și o corectează, în consecință are aceeași valoare MOTA ca și un al doilea algoritm care menține confuzia timp de mai multe secunde sau chiar minute.

Linia albastră/continuă din Figura 45 indică variația în timp a numărului de obiecte estimate de către senzor într-un scenariu cu o singură țintă reală. Numărul crește la 2 în momentul de timp 26, din cauza unei alarme false; revine la 1 în momentul 41 datorită unui obiect ratat și scade la 0 în momentul 51, când algoritmul de tracking corectează alarma falsă, însă continuă să nu detecteze obiectul real. Înainte de momentul 26 și după momentul 61, algoritmul se comportă ideal, fără erori. Se poate observa din linia roșie/punctată că valoarea MOTA își modifică gradientul de fiecare dată când apare sau dispare o eroare suplimentară. Cu cât apar mai multe erori de cardinalitate, cu atât mai repede se îndepărtează MOTA de valoarea sa ideală, unitară. Odată cu corecția erorilor anterioare, valoarea MOTA își oprește descrescerea și revine asimptotic către 1 în intervalele de timp fără erori de cardinalitate.

De notat este că cele două componente ale sistemului de metrici CLEAR trebuie considerate împreună. O precizie de localizare bună arată că un algoritm de urmărire este performant, doar dacă și acuratețea acestuia este aproape de 1. Unul dintre dezavantajele majore ale metricilor CLEAR este dificultatea de a compara performanțele mai multor algoritmi analizați pe baza setului de indicatori MOTP / MOTA: care algoritm este mai bun, cel cu precizie bună, dar cu acuratețe relativ mică

sau invers, acuratețea predomină în decizia de selecție a algoritmului potrivit? Alt dezavantaj al MOTA este că nu reflectă într-un mod adecvat confuziile care apar în timpul unei scene cu mai multe obiecte de interes.




Figura 45: Variația MOTA în cazul unui scenariu cu o singură țintă

5.2 Distanțe de bază

O normă este o funcție care atribuie fiecărui vector din spațiul V , o valoare în mulțimea numerelor reale și pozitive, \mathbb{R}_+ :

$$\|\cdot\| : V \rightarrow \mathbb{R}_+, \quad \mathbb{R}_+ = \{x \in \mathbb{R} \mid x > 0\} \quad (5.3)$$

În general, normele de gradul p , pot fi descrise prin următoarea ecuație:

$$\|X\|_p = \left(\sum_{i=1}^n x_i^p \right)^{1/p}, \quad X \in \mathbb{R}^n \text{ și } p \in \mathbb{R}, 1 \leq p \leq \infty \quad (5.4)$$

Distanțele elementare sau de bază indică gradul de diferențiere între două valori punctiforme dintr-un spațiu de stări considerat V . În funcție de tipul valorilor punctiforme, există tipuri diferite de distanțe de bază. Una dintre acestea, distanța euclidiană, este reprezentată printr-o normă de gradul doi:

$$d_p(X, Y) = \|X - Y\|_p, \text{ cu } p = 2 \quad (5.5)$$

unde X și Y reprezintă vectori n -dimensionali în spațiul de stări V , care conțin de exemplu poziția geometrică, viteza și componentele de accelerație ale unei ținte de interes.

Cercetări actuale [75] iau în considerare anumite grade de incertitudine corespunzătoare atât pozițiilor reale ale obiectelor țintă, cât și pozițiilor estimate de către un sistem de senzori. Utilizarea distanței de bază Hellinger pentru calculul OSPA (vezi subcapitolul 5.3), ca și alternativă la distanța euclidiană folosită în [73] și [74] presupune că procedura de stabilire a poziției reale este și ea ambiguă. În aplicațiile radar, stabilirea cu exactitate a pozițiilor de referință este realizată cu un efort extrem de mare, efectuat de ingineri specialiști și parțial asistați de tool-uri automate de adnotație. Pentru achiziționarea de date reale se utilizează de regulă senzori de referință foarte performanți, și în consecință foarte scumpi, ca de exemplu senzorii

lidar. Ulterior, procesul de achiziție automată este completat de un proces auxiliar, efectuat de specialiști în testare și asigurarea calității.

În cazul obiectelor cu reprezentări extinse (vezi subcapitolul 4.3), fiecare punct caracteristic al unei ținte apare atât în mulțimea de stări reale cât și în cea de valori estimate. Utilizarea distanței Hellinger ca și distanță de bază pentru calculul OSPA, rezultă într-un efort computațional extrem de ridicat. În plus, folosirea unei matrici de covarianță pentru stările reale poate avea rezultate teoretice considerabile, însă este contra-intuitivă pentru aplicațiile radar.

Teza își propune în premieră utilizarea distanței Mahalanobis ca și distanță de bază în calculul OSPA. Distanța Mahalanobis reprezintă distanța dintre un punct determinist dat de poziția reală, stabilită cu exactitate, a unei ținte și valoarea estimată corespunzătoare, caracterizată printr-o distribuție normală [76].

Primul domeniu de utilizare a distanței Mahalanobis a fost în cadrul studiilor antropologice și craniometrice. În esență, problema acestui tip de aplicații constă în stabilirea gradului în care un material osteologic analizat, spre exemplu un craniu, aparține unei grupări etnice de referință. În prezent, distanța Mahalanobis are diverse aplicații, de exemplu în diagnozele medicale sau în prelucrarea datelor statistice obținute de sateliți pe parcursul procesului de monitorizare a obiectelor îndepărtate. Ideea de principiu este utilizarea distanței dintre un punct de testare și un set de distribuții de probabilitate, pentru a stabili apartenența acestui punct unei anumite clase de interes.

În aplicațiile radar, punctul determinist este reprezentat de starea reală x_k a unui obiect urmărit la momentul t_k , în timp ce variabila aleatoare este dată de starea estimată. Pentru o țintă, starea estimată, corespunzătoare la momentul t_k este un vector multidimensional y_k cu coordonatele carteziene de distanță (H, W, L) , viteză (v_H, v_W, v_L) și accelerație (a_H, a_W, a_L) . În cele ce urmează, vom considera y_k ca având o distribuție normală multidimensională, parametrizată de vectorul medie μ_y și matricea de covarianță Σ_y .

Distanța Mahalanobis D_m este adimensională și invariabilă la sistemul de referință [79]. Ea evidențiază corelațiile dintre variabilele unei mulțimi de valori și este definită de formula următoare:

$$D_m^2(x_k) = (x_k - \mu_y)^T \Sigma_y^{-1} (x_k - \mu_y) \quad (5.6)$$

Un senzor radar calculează în fiecare ciclu valorile medii și deviațiile standard pentru toate componentele constitutive ale vectorului său de stare. Aceasta înseamnă că în fiecare ciclu de măsură al radarului, aceluiași punct caracteristic al ținteii reale îi sunt atribuite detecții multiple. Evident, componentele singulare (poziție, viteză, accelerație) sunt corelate, astfel că există multiple valori nenule în matricea de covarianță. Operatorul $()^T$ reprezintă transpusul unui vector. Vectorul medie al stărilor estimate este:

$$\mu_y = (\mu_H, \mu_W, \mu_L, \mu_{v_H}, \mu_{v_W}, \mu_{v_L}, \mu_{a_H}, \mu_{a_W}, \mu_{a_L})^T \quad (5.7)$$

unde matricea de covarianță este:

$$\Sigma_y = \begin{pmatrix} \text{var}(H) & \text{cov}(H, L) & \dots & \text{cov}(H, a_L) \\ \text{cov}(L, H) & \text{var}(L) & \dots & \text{cov}(L, a_L) \\ \vdots & \vdots & \ddots & \vdots \\ \text{cov}(a_L, H) & \text{cov}(a_L, L) & \dots & \text{var}(a_L) \end{pmatrix} \quad (5.8)$$

Să considerăm în continuare un vector de stare tridimensional $EST = (H, W, L)^T$ și patru grupuri diferite de observații, centrate în jurul aceiași ținte cu poziția reală

la sol $x_{GT} = (0; 0; 0)^T$, provenind fiecare de la un algoritm de urmărire diferit. Scopul analizei este de a compara preciziile de localizare ale celor patru algoritmi de tracking generați sintetic, cu respectiv fără a lua în considerare incertitudinile de estimare iminente. Primul algoritm ("Tracker 1" din Tabel 4, având covarianța „Sigma_Y1” din Tabel 3) este cel de referință. Al doilea algoritm ("Tracker2”) prezintă variațe crescute pentru cele trei variabile ale vectorului de stare. Al treilea algoritm de tracking ("Tracker 3”) are o corelație mai ridicată între valorile înălțimii (H) și lățimii (W), în timp ce ultimul algoritm considerat ("Tracker 4”) prezintă o corelație foarte mică între înălțime și lățime. Matricile de covarianță ale celor patru algoritmi de urmărire au fost selectate așa cum se arată în Tabel 3. Corelațiile incrementate sunt marcate cu verde, iar cele decrementate cu roșu.

Sigma_Y1 = [1 0.9 0.8; 0.9 1 0.7; 0.8 0.7 1]
Sigma_Y2 = [2 0.9 0.8; 0.9 2 0.7; 0.8 0.7 2]
Sigma_Y3 = [2 1.8 0.8; 1.8 2 0.7; 0.8 0.7 2]
Sigma_Y4 = [2 0.1 0.8; 0.1 2 0.7; 0.8 0.7 2]

Tabel 3: Matricile de covarianță pentru cei patru algoritmi analizați

Prin incrementarea valorilor medii pe fiecare coordonată cu unu respectiv doi metri, obținem rezultatele din Tabel 4.

EST=(H,W,L) ^T	Mean Vector (1,0,0) ^T		Mean Vector (0,1,0) ^T		Mean Vector (0,0,1) ^T	
	Dm ² [*10e-3]	De ² [*10e-3]	Dm ² [*10e-3]	De ² [*10e-3]	Dm ² [*10e-3]	De ² [*10e-3]
Tracker 1	6625,5	1043	5721,1	949,6	2322,7	1003,8
Tracker 2	885,1		676		693,3	
Tracker 3	2561,1		2670,5		620	
Tracker 4	474,3		557,3		1110,5	
	Mean Vector (2,0,0) ^T		Mean Vector (0,2,0) ^T		Mean Vector (0,0,2) ^T	
	Dm ² [*10e-3]	De ² [*10e-3]	Dm ² [*10e-3]	De ² [*10e-3]	Dm ² [*10e-3]	De ² [*10e-3]
Tracker 1	27334,8	4139,4	22213,3	3775,2	9217,1	4013,6
Tracker 2	3041,2		2630,3		2724,8	
Tracker 3	10831,3		10384		2296,7	
Tracker 4	2038,7		2439,6		3974,1	

Tabel 4: Distanțele Mahalanobis D_m respectiv euclidiană D_e pentru algoritmi analizați (Tracker1-4) cu poziții reale variind în jurul $(0,0,0)^T$

Prima remarcă interesantă bazată pe rezultatele de mai sus, este că cei patru algoritmi de urmărire prezintă diferențe semnificative de performanță în localizarea țintelor, care nu pot fi observate, considerând exclusiv distanța euclidiană. Pătratul distanței euclidiene D_e^2 are în vedere doar eroarea de localizare dintre vectorul cu mediile valorilor estimate și cel de referință, fiind aceeași pentru fiecare din cei patru algoritmi investigați.

În al doilea rând, variațiile crescute ale valorilor înălțimii, lățimii și lungimii conduc la distanțe Mahalanobis D_m^2 îmbunătățite (vezi algoritmul "Tracker 2" comparativ cu algoritmul "Tracker 1"). Sunt șanse mai mari ca un anumit punct real să provină dintr-o distribuție cu dispersie mai mare, decât dintr-una cu dispersie mai

mica (repartiție îngustă). Figura 46 ilustrează acest lucru, pentru un caz unidimensional. Probabilitatea ca un punct de testare să aparțină distribuției Gauss 1 (linia albastră, cu $\mu_1 = 0$ și $\sigma_1 = 1$) este mai mică decât probabilitatea de a aparține distribuției Gauss 2 (linia roșie, cu $\mu_2 = 0$ și $\sigma_2 = 2$), dacă punctul de testare este în afara intervalului dat de cele două puncte de intersecție $[-1,35 \ 1,35]$. Pentru un punct de testare aflat în afara acestui interval, distanța Mahalanobis ar fi mai mare, relativ la distribuția normală 1 (cu albastru), decât relativ la distribuția normală 2 (cu roșu).




Figura 46: Punctele de intersecție între două distribuții normale.

Efectul creșterii, respectiv al descreșterii corelației între două variabile ale vectorului de stare este evidențiat de rezultatele corespunzătoare algoritmilor trei și patru ("Tracker 3" și "Tracker 4") din Tabel 4. O corelație strânsă între înălțimea și lățimea unui obiect-țintă duce la distanțe Mahalanobis mai mari, în timp ce observațiile cu valori individuale slab corelate reduc distanța Mahalanobis, reducând-o la distanța euclidiană, în cazul în care nu există corelații între componente. În acest caz, matricea de covarianță ar fi o matrice diagonală.

5.3 Metoda OSPA

Evaluarea nivelului de performanță al algoritmilor care estimează stările țintelor multiple este mai dificilă decât în cazul unei singure ținte. Problema centrală constă în evaluarea numărului de ține de interes și a locațiilor corespunzătoare în spațiul de stări. Chiar și atunci cardinalitățile dintre mulțimile de date estimate și reale sunt egale, utilizarea directă a unui estimator bazat pe eroarea medie pătratică nu este posibilă, deoarece cele două mulțimi de date nu sunt ordonate.

Pentru a elimina dezavantajele metricilor CLEAR și a extinde aplicabilitatea și asupra scenariilor des întâlnite în sistemele radar imbarcate în autovehicule în care numărul de ținte detectate este diferit de cel al țintelor reale, s-a introdus în [74] metrica OSPA (optimal subpattern assignment). Mulțimile de date reale, respectiv estimate la momentul t_k se notează cu \mathfrak{X}_k și \mathfrak{Y}_k :

$$\mathfrak{X}_k = \{(l_1, x_{k,1}), \dots, (l_m, x_{k,m})\} \quad (5.9.1)$$

$$\mathfrak{Y}_k = \{(s_1, y_{k,1}), \dots, (s_n, y_{k,n})\} \quad (5.9.2)$$

Acestea au indicii de traiectorie invariți în timp $l, s \in \mathbb{N}$ cu cardinalitățile m , respectiv n . Vectorii de stare x_k, y_k sunt N -dimensionali și includ componente ca de exemplu poziția, viteza sau accelerația unei ținte de interes. Metrica OSPA corespunzătoare este dată de formula:

$$D_{p,c}(\mathfrak{X}_k, \mathfrak{Y}_k) = \left[\frac{1}{n} \left(\min_{\pi \in \Pi_n} \sum_{i=1}^m (d_c(\tilde{x}_{k,i}, \tilde{y}_{k,\pi(i)}))^p + (n-m)c^p \right) \right]^{1/p} \quad (5.9.3)$$

unde $\tilde{x}_{k,i} \stackrel{\text{def}}{=} (l_i, x_{k,i})$, $\tilde{y}_{k,\pi(i)} \stackrel{\text{def}}{=} (s_{\pi(i)}, y_{k,\pi(i)})$ și

- $d_c(\tilde{x}, \tilde{y}) = \min(c, d(\tilde{x}, \tilde{y}))$, este distanța de limitare (cut-off) între două traiectorii diferite la momentul t_k , iar d este distanța de bază dată de (5.9.4).
- Π_n este setul de permutări de lungime m și valori în mulțimea $\{1, \dots, n\}$, cu $m \leq n$
- $1 \leq p \leq \infty$ este ordinul metricii OSPA, în mod uzual $p = 2$.

Ultimul termen din ecuația (5.9.3) reprezintă traiectoriile fals pozitive și fals negative, reflectând astfel diferențele de cardinalitate. Parametrul de limitare c este o constantă (de exemplu $c = 20m$) aleasă în așa fel, încât influența perechilor de obiecte foarte îndepărtate să nu predomină în valoarea momentană absolută a OSPA, mascând eventual sursele erorii de localizare la un moment dat. Distanța de bază între cei doi vectori indexați este necesară pentru calculul distanței de limitare:

$$d(\tilde{x}, \tilde{y}) = [d(x, y)^{p'} + (\alpha \bar{\delta}[l, s])^{p'}]^{1/p'} \quad (5.9.4)$$

unde $\bar{\delta}[l, s]$ este complementul operatorului Kronecker, adică $\bar{\delta}[l, s] = 0$ pentru $l = s$ și în rest $\bar{\delta}[l, s] = 1$. Primul termen din suma prezentată în ecuația (5.9.3) reprezintă eroarea de localizare în spațiul de stări și se calculează pentru fiecare moment t_k . Și eroarea de indexare trebuie stabilită pentru fiecare iterație dată în cazul radarului automotive de numărul ciclului radar curent (Figura 47). Similar cu ordinul metricii OSPA p , și ordinul distanței de bază este în mod uzual $p' = 2$ [73], [74].

Analizând variația valorii instantanee a metricii OSPA într-o situație simulată de trafic (Figura 47), se observă că valori ridicate ale OSPA corespund unor distanțe mari între mulțimile de valori estimate, respectiv reale, indicând astfel o performanță modestă a algoritmului de tracking. Pe durata inițializării și după ciclul radar 115, valorile pentru traiectoriile reale nu există, lucru care duce prin definiție la valori nule ale OSPA. După parcurgerea primelor cicluri, metrica are un prim maxim local datorat timpului relativ mare pentru inițializare. În această fază, țintele reale prezente în zona de acoperire a senzorului nu sunt detectate încă, diferența de cardinalitate fiind cea care contribuie exclusiv la valoarea OSPA, pe durata inițializării.

Situația de trafic simulată consideră cinci ținte, provenind din direcții diferite separate unghiular cu 15° , respectiv 30° . Cele opt scenarii investigate (rezultate pentru OSPA respectiv metrici CLEAR în Tabel 5) sunt variante ale aceleiași situații de trafic, cu intersectarea traiectoriilor celor cinci ținte la momentul corespunzător ciclului radar 70. În momentul de intersectare, valoarea OSPA are un al doilea maxim local, cauzat de un număr relativ mare de erori de indexare. Indexarea efectuată de regulă cu algoritmul Munkres [80] devine dificilă când țintele se apropie foarte tare unele de altele.




Figura 47: Variația OSPA într-o situație de trafic

Prin reducerea parametrului de limitare c , se poate ajusta influența pe care o au alarmele false și țintele nedetectate asupra valorii instantanee a OSPA.

Traietoriile celor cinci ținte din scenariile analizate au fost generate utilizând MATLAB, iar variația metricii OSPA a fost calculată folosind algoritmul descris mai sus, având la bază implementarea dată în [81]. Țintele sunt considerate ca având o reprezentare extinsă (capitolul 4.3), cu câte trei puncte specifice pentru fiecare țintă: cel mai apropiat punct față de poziția sensorului (closest, C), cel din extrema stângă (most-left, L), respectiv cel din extrema dreaptă (most-right, R). În cele opt scenarii se variază unghiul de separație între direcțiile țintelor, probabilitatea de detecție, intensitatea reflexiilor parazite și α , parametrul de penalizare a erorilor de indexare.

Implementarea algoritmului OSPA demonstrează clar avantajele acestei metrici. Ea reprezintă o combinație eficientă a preciziei și a acurateței de estimare a unui algoritm de tracking, corelată cu o caracterizare intuitivă a perechilor nepotrivite sau asociate fals între ținte și stările detectate. În scenariul 6 din Tabel 5, valorile medii ale MOTA sunt identice pentru cele trei puncte de referință (CLR), în timp ce OSPA indică diferențele dintre metricile asociate celor trei puncte, cauzate de precizii de localizare diferite. În scenariul 8, valorile MOTA sunt din nou aproape egale (0.88, 0.89, 0.88), doar cu ajutorul OSPA putând fi evidențiate diferențele dintre cele trei puncte, datorate timpilor diferiți în care persistă eroarea de indexare pentru fiecare punct (CLR) în parte.

Scenariu	MOTA						OSPA									
	C	L	R	m	fp	nme (CLR)	OSPA(CLR)			eroare de localizare (CLR)			eroare de indexare (CLR)			eroare de cardinalitate
1_5crossTrgts_30degrees	0.88	0.89	0.88	5	5	10 6 8	7.13	8.36	8.44	3.12	4.52	4.52	0.42	0.25	0.34	3.59
2_5crossTrgts_15degrees	0.87	0.86	0.86	5	5	12 15 14	7.24	8.75	8.73	3.02	4.36	4.35	0.63	0.8	0.8	3.59
3_5crossTrgts_prob0.75	0.75	0.74	0.74	5	5	6 9 8	9.09	10.35	10.38	2.73	3.83	3.94	0.24	0.4	0.32	6.12
4_5crossTrgts_prob0.6	0.63	0.63	0.63	5	5	8 7 8	10.54	11.62	11.54	2.5	3.54	3.5	0.32	0.36	0.32	7.72
5_5crossTrgts_clutter50	0.8	0.81	0.8	5	5	17 22 19	20.44	20.7	20.54	13.96	14.09	14.01	2.89	3.02	2.94	3.59
6_5crossTrgts_clutter1	0.9	0.9	0.9	5	5	0 0 2	4.27	8.03	8.07	0.68	4.45	4.39	0	0	0.08	3.59
7_5crossTrgts_alfa0	0.88	0.89	0.88	5	5	10 6 8	6.71	8.11	8.11	3.12	4.52	4.52	0	0	0	3.59
8_5crossTrgts_alfa12.5	0.88	0.89	0.88	5	5	10 6 8	6.92	8.24	8.28	3.12	4.52	4.52	0.21	0.13	0.17	3.59

Tabel 5: Avantajele metodei OSPA-T față de MOTA/MOTP, în opt scenarii diferite

5.4 Mulțimi de valori finite aleatorii

Algoritmi bazați pe asocierea explicită detecție-țintă cum ar fi urmărirea cu ipoteze multiple (Multiple Hypotheses Tracking, MHT) [82], [83] asocierea probabilistică și comună a datelor (Joint Probabilistic Data Association, JPDA) [84] sau MHT probabilistic (PMHT) [85] au ca și dezavantaj major complexitatea ridicată necesară de calcul [86], [87]. Calculele devin tot mai complexe pe măsură pe crește numărul de ținte și de observații. Tehnica de aproximare folosită la filtrele PHD depășește cu mult pe cea utilizată în cazul asocierii explicite detecție-țintă, reușind reducerea complexității de calcul, până la o dependență liniară de numărul de detecții și de numărul de ținte. Scopul final rămâne același, și anume a se estima numărul curent de ținte și stările lor, având la bază unui set de observații.

O mulțime de valori finite aleatorii (random finite set, RFS) [88] reprezintă valorile finite luate de o variabilă aleatoare, având ca diferență principală față de un vector aleatoriu, faptul că există un număr aleatoriu de componente constitutive care generează valori aleatorii, în timp ce un vector aleatoriu este compus din valorile aleatorii ale unei singure componente. Țintele și observațiile sunt reprezentate în spațiul finit aleatoriu ca și o mulțime de valori de stare, respectiv o mulțime de valori de observație. În consecință, se vor considera în continuare două RFS (una pentru stările reale și una pentru observații). Pentru caracterizarea cardinalității unui RFS, este necesară o distribuție discretă în \mathbb{N} , mulțimea numerelor naturale. O singură distribuție comună tuturor țintelor, dată fiind cardinalitatea lor, completează reprezentarea statistică a unui RFS.

Funcția de intensitate a unui RFS X la poziția x , denumită și momentul său de ordinul întâi, indică densitatea de probabilitate a numărului așteptat de puncte care apare la poziția x . Prin definiție, intensitatea sau măsura momentului de ordin întâi V este definită ca:

$$V(B) = E[|(X \cap B)|] \quad (5.10.1)$$

pentru fiecare submulțime B din spațiul de stări. Dacă pentru fiecare submulțime B , V poate fi scris sub forma:

$$V(B) = \int_B v(x) dx \quad (5.10.2)$$

atunci $v(x)$ reprezintă funcția de intensitate, sau mai simplu intensitatea RFS.

RFS X de tip Poisson în spațiul \mathbb{R}^d reprezintă o categorie importantă de mulțimi de valori finite aleatorii, deoarece este descrisă exclusiv prin momentul său de ordinul întâi $v(x)$. Distribuția discretă a cardinalității este de tip Poisson cu media $N = \int v(x) dx$. Cele N componente constitutive ale RFS sunt reciproc independente și distribuite identic (i.i.d), fiecare având densitatea de probabilitate $v(x)/N$. Densitatea de probabilitate a unui RFS Poisson este dată de:

$$\pi(\{x_1, x_2, \dots, x_n\}) = K^n \cdot e^{-N} \prod_{i=1}^n v(x_i) \quad (5.11)$$

unde K este volumul unitar al spațiului de stări.

O altă categorie importantă de mulțimi cu valori finite aleatorii este dată de RFS de tip Bernoulli. Un asemenea RFS este descris în mod unic de doi parametri

(r, p) , unde r este probabilitatea ca RFS să conțină exact un element. Acest element are densitatea de probabilitate p . În consecință, probabilitatea ca RFS să fie mulțimea vidă este $1 - p$. Prin definiție, RFS Bernoulli poate fi fie mulțimea vidă fie poate conține exact un element. Densitatea de probabilitate a RFS Bernoulli este dată de formula:

$$\pi(x) = \begin{cases} 1 - r, & X = \phi \\ Krp(x), & X = \{x\} \\ 0, & \text{altfel} \end{cases} \quad (5.12)$$

RFS multi-Bernoulli este definit ca o uniune a mai multor mulțimi cu valori finite aleatorii Bernoulli independente $X^{(i)}$, cu perechile de parametri corespunzători $(r^{(i)}, p^{(i)})$. Funcția sa de densitate de probabilitate este:

$$\pi(X) = \begin{cases} \prod_{i=1}^M (1 - r^{(i)}), & n = 0 \\ K^n \prod_{i=1}^M (1 - r^{(i)}) g(p^{(i)}(x_i)), & n \leq M \\ 0, & n > M \end{cases} \quad (5.13)$$

unde M reprezintă numărul de RFS-uri Bernoulli constituenți, iar

$$g(p^{(i)}(x)) = \sum_{i_1 \neq i_2 \neq \dots \neq i_n} \prod_{j=1}^n \frac{r^{(i_j)} p^{(i_j)}(x_j)}{1 - r^{(i_j)}} \quad (5.14)$$

5.5 Filtre pentru ținte singulare

Problema urmăririi unor ținte singulare este modelată de ecuațiile de filtrare neliniare în timp discret [89], [90]. Filtrul Bayes reprezintă un model recursiv pentru estimarea stării, având ca elemente centrale modelul de mișcare (subcapitolul 4.1). El permite estimarea stării unei ținte pe baza informațiilor provenite din observația curentă, fără a trebui luate în considerare observațiile precedente. Un obiect aflat în mișcare într-un mediu ideal, fără surse de control sau pierderi ale energiei cinetice, își păstrează starea inițială pe durata întregii perioade de observare. În cazul unui autovehicul, apar forțe de frecare între roți și carosabil, între caroserie și atmosferă și pe de altă parte pierderi ale energiei cinetice datorate unor factori perturbatori cum ar fi rafale de vânt sau energia dinamică rezultată în momentul depășirii unui alt autovehicul. Pentru a contracara aceste pierderi, sistemul de propulsie al mașinii trebuie să furnizeze permanent energie suplimentară. Traectoria autovehiculului este controlată în mod uzual de către șofer prin activarea unuia din modurile de control aflate la dispoziția sa: accelerare, frânare sau ghidaj. În viitor, mașinile cu grad înalt de autonomie, L3, L4 și L5 [91] vor decide singure modul de control al mașinii. Considerând observațiile z și informațiile legate de modul de control al țintei pentru a o muta dintr-o stare în alta u , filtrul Bayes permite estimarea stării curente a sistemului, $p(x|z_t, u_t)$.

Starea prezisă a unei ținte la un anumit moment de timp x_t este definită după cum urmează:

$$bel(x_t) = p(x_t | z_{1:t}, u_{1:t}) \quad (5.15)$$

Aceasta este condiționată de toate observațiile precedente $z_{1:t}$ și toate controalele precedente $u_{1:t}$. Prin aplicarea legii lui Bayes,

$$p(a|b) = p(b|a) \cdot p(a)/p(b) \quad (5.16)$$

și luând în considerare modelul Markov [92] și relația probabilității totale, obținem ecuațiile de filtrare Bayes, reprezentate ca fiind un proces în doi pași, (5.17) și (5.18). Starea prezisă, bazată pe comanda curentă u_t este:

$$\overline{bel}(x_t) = \int p(x_t|u_t, x_{t-1}) \overline{bel}(x_{t-1}) dx_{t-1} \quad (5.17)$$

Al doilea pas, cel de corecție, prezintă starea țintei după ce se iau în considerare observațiile curente z_t :

$$bel(x_t) = \eta p(z_t|x_t) \overline{bel}(x_t) \quad (5.18)$$

cu η fiind o constantă de normalizare. În acest fel, se obține o schemă de actualizare recursivă, care permite estimarea stării țintei pe baza stării sale anterioare x_{t-1} , a comenzii curente de control a mișcării u_t și a observației curente z_t .

O implementare particulară a filtrului Bayes este filtrul Kalman. Acesta presupune că atât modelul de mișcare cât și modelul de observație al țintelor sunt modele liniare și gaussiene:

$$x_t = A_t x_{t-1} + B_t u_t + \varepsilon_t \quad (5.19.1)$$

$$z_t = C_t x_t + \delta_t \quad (5.19.2)$$

Matricea A_t exprimă modul în care starea țintei se modifică atunci când nu se execută nicio comandă de control (u_t este zero), adică modul intrinsec de modificare a sistemului. Ea este de obicei matricea de identitate (elementele pe diagonala principală unu, în rest zero). Dacă de exemplu rafale de vânt modifică orientarea sau poziția unei ținte, atunci matricea A_t capătă elemente noi, care reprezintă exact aceste influențe externe. Matricea B_t din (5.19.1) caracterizează modul în care comanda curentă afectează noua stare, reflectând proprietățile fizice ale țintei. Al treilea parametru C_t descrie modul în care datele din lumea reală, deci informațiile legate de pozițiile reale în spațiul de stări, sunt utilizate în modelul de observații. Cu alte cuvinte, C_t arată la ce ne putem aștepta să observăm, având în vedere că ținta se află într-o stare cunoscută, specificată. Termenii ε_t și δ_t reprezintă variabilele de zgomot corespunzătoare mișcării respectiv procesului de observație și sunt presupuse a avea distribuție Gauss cu valori medii zero și matrici de covarianță R_t respectiv Q_t .

Procesul Bayes în doi pași din (5.19.1) și (5.19.2) conduce în ipoteza modelelor liniare și gaussiene, la ecuațiile Kalman de actualizare în timp și de actualizare a informațiilor. Parametrii preziși ai distribuției gaussiene $\mathcal{N}(\bar{\mu}_t, \bar{\Sigma}_t)$ sunt:

$$\bar{\mu}_t = A_t \mu_{t-1} + B_t u_t \quad (5.20.1)$$

$$\bar{\Sigma}_t = A_t \Sigma_{t-1} A_t^T + B_t u_t + R_t \quad (5.20.2)$$

După ce se aplică pasul de corecție, obținem parametrii statistici ai distribuției stării curente, caracterizată prin media μ_t și matricea de covarianță Σ_t .

$$\mu_t = \bar{\mu}_t + K_t (z_t - C_t \bar{\mu}_t) \quad (5.21.1)$$

$$\Sigma_t = (I - K_t C_t) \bar{\Sigma}_t \quad (5.21.2)$$

Rezultatul înmulțirii a mai multor distribuții Gauss este tot o distribuție Gauss cu valori medii ponderate. Factorul de câștig Kalman K_t mediază între distribuția observațiilor și distribuția valorilor estimate și se calculează după cum urmează:

$$K_t = \bar{\Sigma}_t C_t^T (C_t \Sigma_t C_t^T + Q_t)^{-1} \quad (5.22)$$

Ipoțeza legată de liniaritatea proceselor de observație, respectiv de mișcare a țintelor nu corespunde proceselor reale, ci servește la construirea unui model matematic simplificat. Țintele reale se deplasează pe traiectorii neliniare, cu poziții, viteze și accelerații variind diferit în intervale echidistante de timp. Observațiile sunt de regulă rezultatul unor transformări neliniare, iar distribuțiile actualizate iterativ sunt de asemenea non-gaussiene. Filtrul Kalman extins (EKF) rezolvă această problemă prin liniarizarea locală a funcției de transfer de la starea precedentă la cea curentă (subcapitolul 4.2).

5.6 Filtre PHD

Dezvoltat ca o aproximare a recursiunii Bayes pentru scenarii cu ținte multiple, filtrul de densitate de probabilitate a ipotezelor (probability hypothesis density, PHD) [88] propagă iterativ momentul statistic posterior al multi-obiectului comun. Filtrul prezintă rezultate performante în ipoteza Poisson (subcapitolul 5.4), adică atunci când raportul semnal/zgomot (signal-to-noise ratio, SNR) este atât de mare, încât densitatea posterioară a RFS poate fi aproximată prin PHD, iar interacțiunile dintre ținte pot fi neglijate [88]. Algoritmii de tracking PHD au capacitatea de a detecta și urmări obiecte care apar și dispar în zona, respectiv din zona de acoperire a unui senzor. Din multitudinea de filtre pentru urmărirea multi-țintelor, acesta este unul dintre cele mai ușor de implementat și de asemenea foarte eficient din punct de vedere al complexității de calcul.




Figura 48: Filtru PHD cu două ținte, coordonate în metri

În scenariul din Figura 48, sunt prezentate două mașini aflate în mișcare uniformă cu viteză constantă (subcapitolul 4.1.1), într-un sistem cartezian x-y. Mașinile pornesc din pozițiile inițiale (3,-3) respectiv (-4, 4). În iterația imediat următoare, modelul Matlab generează câte 10 detecții în jurul fiecărei ținte și actualizează după 0,1 secunde, pozițiile celor două obiecte de interes. Atât detecțiile grupate în jurul pozițiilor reale ale mașinilor cât și noile poziții calculate iterativ prin filtrul PHD pot fi văzute în Figura 48.

Similar filtrelor pentru ținte singulare, filtrul PHD poate fi reprezentat ca un proces în doi pași. În mod recursiv se calculează valorile PHD a priori $D_{k|k-1}(x)$, deci pentru densitatea de probabilitate prezisă și valorile PHD a posteriori $D_{k|k}(x)$, luând în considerare observațiile făcute la momentul curent. Intensitatea prezisă este afectată de ținte care apar, se înmulțesc (de exemplu când pasagerii coboară dintr-o mașină) sau dispar din câmpul de acoperire al senzorului. După acumularea observațiilor suplimentare la momentul de timp curent, funcția de intensitate este actualizată luând în considerare și influențele parazitare în pasul de corecție. Este de subliniat că funcția de intensitate reprezintă o stare a unui obiect singular. Prin evitarea pasului de asociere între detecții și setul de ținte disponibile pentru actualizarea iterativă a traiectoriilor, algoritmi bazeți pe filtrele PHD au o complexitate computațională net superioară, comparativ cu metodele clasice ce necesită asocierea explicită, cum ar fi MHT [82], JPDA [84] sau PMHT [85].

Dezavantajul filtrului PHD general este dat de capacitatea sa slabă de determinare a cardinalității unui RFS în condiții cu SNR nefavorabil. Astfel, aplicabilitatea filtrului PHD general este limitată la scenarii relativ simple, cu probabilități de detecție mari și cu intensități neglijabile ale ecurilor perturbatoare.

5.6.1 Filtrul GM-PHD

Filtrul PHD cu combinație gaussiană (GM-PHD) oferă o soluție analitică a filtrului generic PHD, presupunând că modelul de mișcare pentru multi-țintă este liniar și gaussian [93]. Abordarea GM-PHD este similară cu modul în care filtrul Kalman rezolvă analitic ecuațiile Bayes, însă în ipoteze gaussiene și liniare.

Modelul pentru o multi-țintă liniară și gaussiană presupune că fiecare țintă individuală are un model de mișcare, respectiv de măsurare, gaussian și liniar, iar probabilitățile de detecție și supraviețuire a țintelor sunt independente de stare. În plus, intensitățile RFS-urilor nou născute și derivate, $\gamma_k(\cdot)$ respectiv $\beta_k(x|\zeta)$, pot fi reprezentate ca și combinații gaussiene sub forma:

$$\gamma_k(x) = \sum_{i=1}^{J_{\gamma,k}} w_{\gamma,k-1}^{(i)} \mathcal{N}(x; m_{\gamma,k}^{(i)}, P_{\gamma,k}^{(i)}) \quad (5.31)$$

$$v_{\beta,k|k-1}(x) = \sum_{j=1}^{J_{\beta,k}} \sum_{l=1}^{J_{\beta,k}} w_{k-1}^{(j)} w_{\beta,k}^{(l)} \mathcal{N}(x; m_{\beta,k|k-1}^{(j,l)}, P_{\beta,k|k-1}^{(j,l)}) \quad (5.32)$$

Pentru a putea urmări evoluția în timp a intensităților RFS de interes, este necesară cunoașterea modului de variație a parametrilor statistici determinanți ai acestora: factorii de pondere $w^{(i)}$ ai funcțiilor de distribuție gaussiene, respectiv valorile medii $m^{(i)}$ și varianțele corespunzătoare $P^{(i)}$ funcțiilor de distribuție constitutive.

Dacă o țintă intră în zona de acoperire a unui senzor, fiind independentă de alte ținte deja detectate, atunci acest proces este numit ca naștere a țintei respective.

Acest lucru are loc, de exemplu, la intrări pe autostradă sau în apropierea unui aeroport, în cazul aplicațiilor aeronautice. Pentru țintele derivate, existența lor depinde de prezența altor ținte, ca de exemplu în cazul unor rachete lansate de către un avion de vânătoare, când surse punctuale noi apar în poziții auxiliare, cauzate de același obiect primar.

În etapa de predicție a fiecărei iterații, formula analitică a intensității RFS este dată de o sumă de trei termeni corespunzători obiectelor supraviețuitoare $v_{S,k}$, derivate $v_{\beta,k}$ și respectiv nou născute γ_k :

$$\overline{v_k(x)} = \overline{v_{S,k}(x)} + \overline{v_{\beta,k}(x)} + \gamma_k(x) \quad (5.33)$$

În [93] sunt prezentate formulele matematice de calcul pentru mediile, covarianțele și factorii de pondere ale componentelor constitutive Gauss ale intensității RFS precise. Acestea au la bază valorile a-priori ale mediilor, covarianțelor respectiv a factorilor de pondere.

Intensitatea RFS corectată ca urmare a observațiilor prelevate la momentul de timp actual este:

$$v_k(x) = (1 - p_{D,k})\overline{v_k(x)} + \sum_{z \in Z_k} v_{D,k}(x; z) \quad (5.34)$$

unde $p_{D,k}$ indică probabilitatea de detecție independentă de stare, calculată la momentul k . Primul termen din (5.34) reprezintă detecțiile eronate, în timp ce a doua sumă constă din termeni de detecție multiplă, care fac parte din noul set de observații. Similar cu pasul de predicție, pasul de corecție oferă formulele matematice pentru calcularea mediilor, covarianțelor și ponderilor pentru $v_k(x)$, atunci când sunt colectate observații suplimentare [93].

Unul dintre avantajele majore ale acestui filtru este acela că, în ipoteza în care intensitățile inițiale ale RFS-urilor nou născute și derivate sunt combinații gaussiene, atunci și intensitățile precise sunt de asemenea combinații gaussiene, la fel și intensitățile posterioare corectate la un anumit moment de timp. Pe măsură ce numărul de componente din reprezentarea combinației gaussiene a intensității RFS crește odată cu numărul de recursiuni, este necesară aplicarea unor metode de aproximare pentru a limita efortul computațional necesar. Acest lucru se obține de regulă prin păstrarea doar a componentelor dominante la fiecare moment de timp. Forma de reprezentare a intensității RFS ca și combinație gaussiană permite o extracție eficientă și mai precisă a stărilor estimate comparativ cu cazul filtrului secvențial Monte Carlo, prezentat în subcapitolul 5.6.3. Extracția este extrem de simplă, deoarece valorile medii ale distribuțiilor Gauss care compun intensitatea posterioară sunt exact maximele locale ale $v_k(x)$ [94].

5.6.2 Filtrul CPHD

Principiul de bază al filtrului PHD cu cardinalitate (CPHD) [95] este de a propaga pe lângă momentul statistic posterior al multi-obiectului și funcția completă de distribuție a numărului de ținte. Comparativ cu un filtru PHD standard, acesta îmbunătățește semnificativ precizia de localizare a țintelor individuale și capacitatea de urmărire a variației numărului de ținte.

Considerând intensitatea posterioară v_{k-1} și distribuția cardinalității posterioare p_{k-1} asociată cu starea multi-obiectului la recursiunea $k-1$, intensitatea prezisă $\overline{v_k(x)}$ respectiv distribuția cardinalității prezise $\overline{p_k(n)}$ la recursiunea k sunt:

$$\overline{v_k(x)} = \int p_{S,k}(\zeta) f_{k|k-1}(x|\zeta) v_{k-1}(\zeta) d\zeta + \gamma_k(x) \quad (5.23)$$

$$\overline{p_k(n)} = \sum_{j=0}^n p_{\Gamma,k}(n-j) \overline{\Pi_k[v_{k-1}, p_{k-1}](j)} \quad (5.24)$$

unde $f_{k|k-1}(x|\zeta)$ este densitatea de probabilitate a tranziției curente a unei ținte singulare, dată fiind starea ei precedentă ζ , iar $p_{S,k}(\zeta)$ reprezintă probabilitatea supraviețuirii ținte condiționată de ζ și

$$\overline{\Pi_k[v, p](j)} = \sum_{l=j}^{\infty} C_j^l \frac{(p_{S,k}, v)^j (1 - p_{S,k}, v)^{l-j}}{(1, v)^l} P(l) \quad (5.25)$$

Distribuția cardinalității pentru ținte apărute spontan la momentul k este $p_{\Gamma,k}(\cdot)$, în timp ce intensitatea RFS corespunzătoare țintelor apărute spontan Γ_k la momentul k este $\gamma_k(\cdot)$. Operatorul $\langle \cdot \rangle$ reprezintă produsul scalar a doua funcții.

Distribuția cardinalității prezise în (5.24) este dată de convoluția dintre distribuția de cardinalitate a obiectelor nou-născute și cea a obiectelor care supraviețuiesc. După actualizare, obținem valorile corectate pentru intensitatea RFS și distribuția de cardinalitate:

$$v_k(x) = \frac{\langle \gamma_k^1[\overline{v_k}, Z_k], \overline{p_k} \rangle}{\langle \gamma_k^0[\overline{v_k}, Z_k], \overline{p_k} \rangle} [1 - p_{D,k}(x)] \overline{v_k(x)} + \sum_{z \in Z_k} \frac{\langle \gamma_k^1[\overline{v_k}, Z_k \setminus \{z\}], \overline{p_k} \rangle}{\langle \gamma_k^0[\overline{v_k}, Z_k], \overline{p_k} \rangle} \psi_{k,z}(x) \overline{v_k(x)} \quad (5.26)$$

$$p_k(n) = \frac{\gamma_k^0[\overline{v_k}, Z_k](n) \overline{p_k(n)}}{\langle \gamma_k^0[\overline{v_k}, Z_k], \overline{p_k} \rangle} \quad (5.27)$$

unde

$$\gamma_k^u[v, Z] = \sum_{j=0}^{\min(|Z|, n)} (|Z| - j)! p_{K,k}(|Z| - j) p_{j+u}^n \times \frac{\langle 1 - p_{D,k}, v \rangle^{n-(j+u)}}{\langle 1, v \rangle^n} e_j(\mathcal{E}_k(v, Z)) \quad (5.28)$$

$$\psi_{k,z}(x) = \frac{\langle 1, \kappa_k \rangle}{\kappa_k(z)} g_k(z|x) p_{D,k}(x) \quad (5.29)$$

$$\mathcal{E}_k(v, Z) = \{v, \psi_{k,z} : z \in Z\} \quad (5.30)$$

Z_k este setul de observații la momentul k . $g_k(\cdot|x)$ este probabilitatea de măsurare a ținte singulare, dată fiind starea x . $p_{D,k}(x)$ exprimă probabilitatea de detecție, dată fiind starea curentă x . $\kappa_k(z)$ este intensitatea RFS asociată reflexiilor parazitare, în timp ce $p_{K,k}(\cdot)$ indică distribuția probabilității reflexiilor parazitare la momentul k . Numitorul din distribuția cardinalității în (5.27) este o constantă de normalizare, iar termenul $\gamma_k^0[\overline{v_k}, Z_k]$ reprezintă probabilitatea setului de observații Z_k , dat fiind numărul de ținte n . Având în vedere aceste lucruri, propagarea distribuției cardinalității poate fi privită ca o recursie Bayesiană.

În simulările din subcapitolul 5.9, se aplică forma filtrului CPHD prezentată mai sus și detaliată în [95].

5.6.3 Filtrul SMC-PHD

Filtrul secvențial Monte Carlo (SMC-PHD) [96] este potrivit pentru situațiile de urmărire a țintelor multiple cu modele dinamice și de observație neliniare și având distribuții de probabilitate non-gaussiene. În aceste cazuri, funcția de intensitate a RFS are reprezentări ne-parametrice. Ideea principală este dată de aproximarea PHD-ului unei multi-ținte cu reuniune de particule, modelată matematic printr-o sumă ponderată de distribuții Dirac, actualizată la fiecare moment k :

$$v_k(x) \approx \sum_{i=1}^{L_k} w_k^{(i)} \delta_{x_k^{(i)}}(x) \quad (5.35)$$

Suma factorilor de pondere $w_k^{(i)}$ este 1, $\sum_{i=1}^{L_k} w_k^{(i)} = 1$ iar L_k reprezintă numărul de particule.

Recursiunea filtrului secvențial Monte Carlo de densitate a ipotezei de probabilitate (SMC-PHD) oferă o metodă de a calcula intensitatea posterioară aproximativă, derivată din reprezentarea sa prin reuniunea de particule din intervalul anterior prin aplicarea operatorilor de predicție ($\Phi_{k|k-1}$) și actualizare, respectiv corecție (Ψ_k):

$$v_k(x) = (\Psi_k \circ \Phi_{k|k-1})v_{k-1}(x) \quad (5.36)$$

Operatorul de predicție $\Phi_{k|k-1}$ modifică factorii de pondere ai aproximării PHD anterioare $w_{k-1}^{(i)}$, prin aplicarea principiului de selecție ponderată atât asupra țintelor rămase cât și asupra celor nou-născute. Pe măsura ce apar ținte noi, numărul de particule necesare pentru a eșantiona aleatoriu spațiul de stări de interes va crește odată cu numărul acestora, J_k . Densitățile selectate pentru țintele supraviețuitoare respectiv nou-născute sunt $q_k(\cdot | x_{k-1}^{(i)}, Z_k)$ și $p_k(\cdot | \cdot, Z_k)$, iar γ_k indică PHD-ul RFS-lui apărut spontan în iterația actuală:

$$w_{k|k-1}^{(i)} = \frac{\phi_{k|k-1}(x_k^{(i)}, x_{k-1}^{(i)}) w_{k-1}^{(i)}}{q_k(x_k^{(i)} | x_{k-1}^{(i)}, Z_k)}, i = 1..L_{k-1} \quad (5.37)$$

$$w_{k|k-1}^{(i)} = \frac{\gamma_k(x_k^{(i)})}{p_k(x_k^{(i)} | Z_k)}, i = L_{k-1} + 1..L_{k-1} + J_k \quad (5.38)$$

$$\phi_{k|k-1}(x_k^{(i)}, x_{k-1}^{(i)}) = b_{k|k-1}(x_k^{(i)} | x_{k-1}^{(i)}) + e_{k|k-1}(x_{k-1}^{(i)}) f_{k|k-1}(x_k^{(i)} | x_{k-1}^{(i)}) \quad (5.39)$$

unde $b_{k|k-1}$ este intensitatea RFS-ului derivat (dacă acesta există), $e_{k|k-1}$ este probabilitatea de supraviețuire pentru țintele individuale, iar $f_{k|k-1}$ denotă densitatea probabilității de tranziție. Operatorul ψ_k de actualizare este aplicat reuniunii de particule, care aproximează intensitatea PHD prezisă, caracterizată prin ponderile $\{\omega_{k|k-1}^{(i)}, x_k^{(i)}\}_{i=1}^{L_{k-1}+J_k}$. Noile ponderi ale particulelor se modifică după cum urmează:

$$w_k^{(i)} = \left[1 - P_D(x_k^{(i)}) + \sum_{z \in Z_k} \frac{\psi_{k,z}(x_k^{(i)})}{\kappa_k(z) + C_k(z)} \right] w_{k|k-1}^{(i)} \quad (5.40)$$

$$C_k(z) = \sum_{j=1}^{L_{k-1}+J_k} \psi_{k,z}(x_k^{(j)}) \omega_{k|k-1}^{(j)} \quad (5.41)$$

$$\psi_{k,z}(x_k^{(i)}) = P_D(x_k^{(i)}) g_k(z|x_k^{(i)}) \quad (5.42)$$

unde $P_D(x_k^{(i)})$ este probabilitatea de detecție a țintelor singulare, g_k reprezintă funcția de verosimilitate a acestora, iar κ_k denotă intensitatea RFS-ului asociat reflexiilor parazitare la un anumit moment k . Procedura de selecție iterativă a particulelor urmează principiul „supraviețuirea celor mai puternici”. Doar eşantioanele cu ponderile cele mai mari sunt păstrate pentru următoarea iterație. Numărul de particule este limitat din cauza restricțiilor impuse de capacitatea limitată de calcul. Pentru extragerea stărilor țintelor, filtrul folosește diferite tehnici de grupare a particulelor, de exemplu media K sau algoritmul de maximizare a valorilor estimate [90].

5.7 Filtrul CB-MB

Principiul filtrului multi-Bernoulli cu cardinalitatea echilibrată pentru multi-ținte (cardinality balanced multi-Bernoulli, CB-MB) [94] este de a aproxima densitatea de probabilitate a unei multi-ținte prin folosirea unei distribuții multi-Bernoulli și prin propagarea în timp a parametrilor ce o caracterizează $(r^{(i)}, p^{(i)})$, descriși în (5.13). Filtrul este aplicabil pentru procesele de comutare binară (pornire / oprire), în care țintele pot apărea sau dispărea dintr-o celulă de rezoluție din câmpul vizual al unui senzor. În plus, distribuțiile țintelor nou-născute nu acoperă spațiul complet de stări, ci evoluează în mod adaptabil [97], ca urmare a noilor seturi de observații. Filtrele Bernoulli sunt potrivite pentru scenariile neliniare și non-gaussiene și prin urmare nu au o soluție analitică. Densitatea posterioară este de obicei aproximată sub forma unei combinații de distribuții gaussiene sau ca și o reuniune de particule [97]. Densitatea multi-Bernoulli dată în (5.13) se notează cu $\pi = \{r^{(i)}, p^{(i)}\}_{i=1}^M$.

După etapa de predicție a fiecărei recursiuni, se obține o densitate multi-țintă la momentul k , constând din două distribuții multi-Bernoulli, una pentru țintele care au supraviețuit $\pi_P = \{r^{(i)}_{P,k|k-1}, p^{(i)}_{P,k|k-1}\}_{i=1}^{M_{k-1}}$ și cealaltă pentru țintele nou-născute $\pi_\Gamma = \{r^{(i)}_{\Gamma,k}, p^{(i)}_{\Gamma,k}\}_{i=1}^{M_{\Gamma,k}}$.

Probabilitatea de existență pentru țintele care au supraviețuit este:

$$r^{(i)}_{P,k|k-1} = r^{(i)}_{k-1} \langle p^{(i)}_{k-1}, p_{S,k} \rangle \quad (5.43)$$

Distribuția spațială a componentei Bernoulli cu indicele i pentru țintele care au supraviețuit este:

$$p_{P,k|k-1}^{(i)}(x) = \frac{\langle f_{k-1}(x|\cdot), p_{k-1}^{(i)} p_{S,k} \rangle}{\langle p_{k-1}^{(i)}, p_{S,k} \rangle} \quad (5.44)$$

unde $f_{k-1}(\cdot|\cdot)$ este densitatea de probabilitate de tranziție a unei ținte singulare, dată fiind starea precedentă ζ , în timp ce $p_{S,k}(\zeta)$ este probabilitatea de supraviețuire a țintelor, probabilitate care depinde de ζ .

Ca și rezultat al pasului de corecție, se obține densitatea actuală a multi-țintei la momentul k , aproximată ca o reuniune a două multi-distribuții Bernoulli. Prima reprezintă țintele nedetectate $\pi_L = \{r_{L,k}^{(i)}, p_{L,k}^{(i)}\}_{i=1}^{M_{k|k-1}}$, în timp ce a doua este distribuția actualizată pe baza noilor observații, prelevate la momentul curent $\pi_U = \{r_{U,k}^{(i)}(z), p_{U,k}^{(i)}(z)\}_{i=1}^{M_{k|k-1}}$. Este de notat că numărul total de componente Bernoulli crește la $M_{k|k-1} = M_{k-1} + M_{\Gamma,k}$ datorită țintelor nou-născute. În consecință, distribuția multi-Bernoulli actualizată va avea forma $\pi_{k|k-1} = \{r_{k|k-1}^{(i)}, p_{k|k-1}^{(i)}\}_{i=1}^{M_{k|k-1}}$.

Pentru prima distribuție multi-Bernoulli, probabilitatea de existență respectiv distribuția spațială sunt date de:

$$r_{L,k}^{(i)} = r_{k|k-1}^{(i)} \frac{1 - \langle p_{k|k-1}^{(i)}, p_{D,k} \rangle}{1 - r_{k|k-1}^{(i)} \langle p_{k|k-1}^{(i)}, p_{D,k} \rangle} \quad (5.45)$$

$$p_{L,k}^{(i)}(x) = p_{k|k-1}^{(i)}(x) \frac{1 - p_{D,k}(x)}{1 - \langle p_{k|k-1}^{(i)}, p_{D,k} \rangle} \quad (5.46)$$

unde $p_{D,k}(x)$ exprimă probabilitatea de detecție dependentă de starea curentă.

A doua distribuție multi-Bernoulli, corespunzătoare țintelor actualizate pe baza observațiilor din iterația actuală, are parametrii descriptivi:

$$r_{U,k}^{(i)}(z) = \frac{\sum_{i=1}^{M_{k|k-1}} \frac{r_{k|k-1}^{(i)} (1 - r_{k|k-1}^{(i)}) \langle p_{k|k-1}^{(i)}, \psi_{k,z} \rangle}{(1 - r_{k|k-1}^{(i)}) \langle p_{k|k-1}^{(i)}, p_{D,k} \rangle^2}}{\kappa_k(z) + \sum_{i=1}^{M_{k|k-1}} \frac{r_{k|k-1}^{(i)} \langle p_{k|k-1}^{(i)}, \psi_{k,z} \rangle}{1 - r_{k|k-1}^{(i)} \langle p_{k|k-1}^{(i)}, p_{D,k} \rangle}} \quad (5.47)$$

$$p_{U,k}^{(i)}(x) = \frac{\sum_{i=1}^{M_{k|k-1}} \frac{r_{k|k-1}^{(i)} p_{k|k-1}^{(i)} \psi_{k,z}}{1 - r_{k|k-1}^{(i)} \langle p_{k|k-1}^{(i)}, p_{D,k} \rangle}}{\sum_{i=1}^{M_{k|k-1}} \frac{r_{k|k-1}^{(i)} \langle p_{k|k-1}^{(i)}, \psi_{k,z} \rangle}{1 - r_{k|k-1}^{(i)} \langle p_{k|k-1}^{(i)}, p_{D,k} \rangle}} \quad (5.48)$$

unde $\psi_{k,z}(x) = g_k(z|x)p_{D,k}(x)$, Z_k este setul de observații la momentul k , $g_k(\cdot|x)$ este verosimilitatea de măsurare a fiecărei ținte singulare, dată fiind starea x , iar $\kappa_k(z)$ este intensitatea reflexiilor parazitare.

Avantajul central al filtrului CB-MB constă în modelarea eficientă a funcțiilor de distribuție de probabilitate corespunzătoare țintelor nou-născute. Spre deosebire de filtrul secvențial Monte Carlo, prezentat în subcapitolul 5.6.3, care necesită un număr considerabil de particule pentru localizarea țintelor noi, filtrul CB-MB utilizează un mecanism adaptiv de stabilire a distribuțiilor țintelor noi, oferind rezultate comparabile cu algoritmi care presupun că numărul de ținte noi este cunoscut [97].

Evident, în situațiile de trafic real, numărul de ținte noi este necunoscut și variază în timp.

5.8 M-OSPA cu factor de formă pentru ținte extinse

Un avantaj important, atunci când evaluăm performanțele algoritmilor de urmărire, este dat de faptul că valorile medii și de auto-varianță sunt cunoscute pentru fiecare mulțime de valori din setul de observații [64]. Spre deosebire de algoritmi de urmărire, în cazul determinării metricilor de performanță nu este necesară stabilirea parametrilor statistici ai setului de observații. După cum s-a arătat în subcapitolul 5.3, valoarea instantanee a metricii de asociere optimă intra-model (optimal subpattern assignment, OSPA), considerând mulțimile de stări reale \mathfrak{X}_k și respectiv estimate \mathfrak{Y}_k este dată de formula:

$$D_{p,c}(\mathfrak{X}_k, \mathfrak{Y}_k) = \left[\frac{1}{n} \left(\min_{\pi \in \Pi_n} \sum_{i=1}^m (D_c(\tilde{x}_{k,i}, \tilde{y}_{k,\pi(i)}))^p + (n-m)c^p \right) \right]^{1/p} \quad (5.49)$$

$\tilde{x}_{k,i} \stackrel{\text{def}}{=} (l_i, x_{k,i})$, $\tilde{y}_{k,\pi(i)} \stackrel{\text{def}}{=} (s_{\pi(i)}, y_{k,\pi(i)})$ unde l_i și $s_{\pi(i)}$ sunt indicii traiectoriilor reale respectiv estimate la momentul k .

- $D_c(\tilde{x}, \tilde{y}) = \min(c, D_m(\tilde{x}, \tilde{y}))$, este distanța de limitare (cut-off) între două traiectorii diferite la momentul t_k , iar D_m este distanța Mahalanobis dată de (5.51).
- Π_n este setul de permutări de lungime m și valori în mulțimea $\{1, \dots, n\}$, cu $m \leq n$, n și m sunt cardinalitățile lui \mathfrak{X}_k , respectiv \mathfrak{Y}_k .
- $1 \leq p \leq \infty$ este ordinul metricii OSPA, în mod uzual $p = 2$.

Această teză consideră reprezentarea extinsă a obiectelor de interes [60], [64], caz în care fiecare țintă generează $L = 3$ reflexii per scanare: punctul cel mai din stânga (L), cel central (C) și cel mai din dreapta (R). Numărul instantaneu de ținte reale este n , iar cel al țintelor observate este m . Se aplică procedura de calcul M-OSPA, bazată pe distanța Mahalanobis [64] pentru a evalua performanțele de urmărire a algoritmilor analizați. Inițial, se calculează distanțele euclidiene între toate perechile de puncte centrale (C), din mulțimea de stări reale cu lungimea n , notate în continuare cu $\| \cdot \|$.

Dacă $\min_{i,j} \|x_i, x_j\| \geq f$ atunci

$$D_{p,c,f}(\mathfrak{X}_k, \mathfrak{Y}_k) = \left[\frac{1}{n} \left(\min_{\pi \in \Pi_n} \sum_{i=1}^m (D_c(\tilde{x}_{k,i}, \tilde{y}_{k,\pi(i)}))^p + (n-m)c^p \right) \right]^{1/p}, \text{ altfel}$$

$$D_{p,c,f}(\mathfrak{X}_k, \mathfrak{Y}_k) = \left[\frac{1}{n'} \left(\min_{\pi \in \Pi_{n'}} \sum_{i=1}^{m'} (D_c(\tilde{x}_{k,i}, \tilde{y}_{k,\pi(i)}))^p + (n'-m')c^p \right) \right]^{1/p} \quad (5.50)$$

unde $n' = L \cdot n$; $m' = L \cdot m$, L este numărul de puncte de referință per țintă, iar f reprezintă factorul de formă al țintelor de interes. Similar cu (5.49), distanța de bază în $D_c(\tilde{x}, \tilde{y}) = \min(c, D_m(\tilde{x}, \tilde{y}))$, este dată de distanța Mahalanobis. Parametrii statistici ai observațiilor sunt reprezentați de către vectorul de valori medii μ_y și de matricea de covarianță Σ_y . Distanța Mahalanobis D_m este adimensională [79]. Ea evidențiază corelațiile dintre variabilele constitutive ale vectorului de stare și are forma (5.6).

5.9 Simulări și rezultate

Pentru a demonstra capacitatea puternică de selecție a algoritmului de tracking optim, oferită de metrica M-OSPA, sunt prezentate în continuare rezultatele simulărilor corespunzătoare a trei filtre PHD diferite, EKF-PHD, EKF-CPHD și SMC-CB-MB, utilizând ca bază setul de aplicații MATLAB prezentat în [81]. Fiecare țintă extinsă este reprezentată prin trei puncte caracteristice (cel mai apropiat, cel mai din stânga și cel mai din dreapta punct). Conform modelelor dinamice neliniare, prezentate în [36], considerăm un model generic de mișcare cu rotație constantă cu cinci componente (lungime, lățime, viteză longitudinală, viteză laterală, rată de rotație) și un model de observație cu două componente (distanța și direcția). Similar cu [64] și [63], presupunem că stările estimate au matricile de covarianță $\Sigma_{Y_1}.. \Sigma_{Y_4}$ de dimensiunea $[2 \times 2]$, corespunzătoare a patru implementări diferite ale filtrelor PHD analizate:

$$\Sigma_{Y_1} = \begin{bmatrix} 1 & 0.9 \\ 0.9 & 1 \end{bmatrix}; \Sigma_{Y_2} = \begin{bmatrix} 2 & 0.9 \\ 0.9 & 2 \end{bmatrix}$$

$$\Sigma_{Y_3} = \begin{bmatrix} 2 & 1.8 \\ 1.8 & 2 \end{bmatrix}; \Sigma_{Y_4} = \begin{bmatrix} 2 & 0.1 \\ 0.1 & 2 \end{bmatrix}$$

Matricile de covarianță caracterizează statistic reflexiile generate de către un anumit punct caracteristic al unei ținte de interes la un moment dat. Astfel, valorile folosite pentru exemplificare, selectate mai sus reprezintă valori momentane. Matricile de covarianță sunt pătrate și simetrice, având ca elemente valorile de auto-varianță pe diagonala principală și valorile de covarianță între perechile de componente considerate, în rest.

Ideea centrală urmărită de alegerea celor patru matrici de covarianță este de a crea posibilitatea de analiză a algoritmilor de tracking, care se deosebesc între ei, fie prin erorile medii pătratice corespunzătoare componentelor modelului de observație, fie prin valorile funcției de covarianță dintre perechile de componente.

Matricea de covarianță Σ_{Y_3} are o corelație relativ mare între valorile măsurate pentru distanță, respectiv direcție, în timp ce matricea Σ_{Y_4} caracterizează un algoritm de tracking cu valori ale distanței, respectiv direcției, cvasi-independente.

Selecția parametrului de limitare c și al ordinului p pentru M-OSPA urmează criteriile prezentate în [73] și [94]. Pentru simulări stabilim factorul de formă $f = 3m$, reprezentând jumătate din diagonala unui autovehicul de clasă medie, precum și parametrul de limitare $c = 10m$. Numărul de puncte caracteristice per țintă este $L = 3$ (punctul cel mai la stânga, cel mai apropiat și cel mai la dreapta). Vectorul de stare corespunzător valorilor estimate, matricile de covarianță și respectiv valorile M-OSPA sunt considerate pentru fiecare punct caracteristic.

În continuare sunt prezentate două situații în trafic, la care participă patru respectiv trei autovehicule. Ambele situații corespund unor manevre de parcare sau de mișcări intravilane cu viteze și distanțe de deplasare relativ reduse (Figura 49 și Figura 54). Figura 50 și Figura 55 indică pozițiile longitudinale (x) și laterale (y) ale fiecărui grup de trei puncte reprezentative, luate în considerare per țintă în timpul de observare. Grupurile de trei puncte caracteristice, corespunzătoare aceluiași autovehicul, sunt marcate grafic cu aceeași culoare. Timpul de observație este de 100 de cicluri radar cu 50ms pentru fiecare ciclu, totalizând 5 secunde. În plus, se presupune că nu apar ținte derivate (atunci când surse punctuale noi ar apărea la poziții auxiliare, cauzate de un anumit obiect primar) și că există patru locații posibile

în care pot apărea ținte nou-născute, adică intensitatea RFS de apariție gaussiană γ_k constă din patru componente gaussiene ponderate, așa cum se arată în subcapitolul 5.6.1.




Figura 49: Manevră de parcare cu patru autovehicule. Cercurile indică locul în care țintele apar în câmpul de acoperire, iar triunghiurile indică locul în care țintele dispar. Axele în [cm].

La momentele de timp corespunzătoare ciclurilor radar 20, 40 și 80, cardinalitatea reală a RFS-ului se modifică, pe măsură ce țintele apar sau dispar în respectiv din câmpul de acoperire al senzorului (în Figura 50 sus: ținta verde apare la ciclul 20 și dispare la ciclul 80, în timp ce ținta cyan apare la ciclul 40 și dispare la ciclul 100). În vecinătatea acestor momente de timp, analiza se axează pe cât de bine poate determina fiecare algoritm numărul corect de ținte. Nepotriviri pot apărea în jurul momentelor de timp 40, 50 și 60, atunci când traiectoriile țintelor se încrucișează (Figura 50).




Figura 50: Manevră de parcare cu patru autovehicule, sus: poziția x, jos: poziția y pentru fiecare punct reprezentativ (punctul cel mai la stânga, cel mai apropiat și cel mai la dreapta) per țintă. Timpul este exprimat în cicluri radar.

În continuare, se analizează performanța algoritmilor de tracking din punct de vedere al timpului de inițializare, al vitezei și acurateții în ceea ce privește determinarea cardinalității, al nivelului erorilor de localizare și al numărului de nepotriviri.

Pentru cele trei tipuri de filtre, sunt considerate ambele valori, OSPA și respectiv, M-OSPA cu factor de formă. În Figura 51, Figura 52 și Figura 53 sunt reprezentate erorile de localizare, utilizând OSPA și M-OSPA cu factor de formă în funcție de timp. Cu cât valorile instantanee sunt mai mici, cu atât algoritmul corespunzător este mai performant. Inițializarea are loc în intervalul $[0, 10]$ cicluri radar, acolo unde filtrele lente vor prezenta valori mai mari. În general, viteza de inițializare nu reprezintă un criteriu de performanță absolut, ci trebuie încadrat în contextul complet al elementelor care contribuie la nivelul de performanță al algoritmilor de tracking pentru ținte multiple. Astfel, detecția rapidă a țintelor noi care apar în zona de acoperire a unui senzor crește riscul de a clasifica reflexii perturbatoare sau datorate zgomotului de procesare ca fiind ținte reale. În acest caz, inițializarea rapidă este obținută concomitent cu creșterea ratei de alarme false.

Pentru toate simulările efectuate se poate constata că valorile instantanee ale matricelor de covarianță influențează semnificativ valoarea M-OSPA cu factor de formă, spre deosebire de valoarea OSPA standard, care nu ia în considerare natura aleatoare a componentelor din vectorul de stare a țintelor de interes. O corelație redusă între componente (vezi cazul Σ_{y_s} în culoarea cyan), în cazul analizat între distanța și orientarea relativă a unei ținte față de poziția senzorului, implică o valoare M-OSPA mai redusă, deci reflectă un grad mai ridicat de performanță al algoritmului de tracking. Durata medie de calcul M-OSPA este cu 20% mai mică decât durata medie de calcul OSPA, considerând o mediere pe 600 de simulări MATLAB. Spre exemplu, 100 de simulări ale manevrei de parcare, cu patru autovehicule din Figura 50, pentru filtrul EKF-PHD au rezultat într-o durată medie de execuție de 50ms pentru OSPA, respectiv de 40ms pentru M-OSPA cu factor de formă. Această reducere consistentă a timpului de procesare reprezintă un avantaj considerabil al noii metrici, aceasta fiind implementată într-o aplicație de tip big-data pentru validarea sistemului radar utilizat în mașinile Mercedes-Benz cu anul de început al producției de serie (SOP) 2020.

În cazul 1 (Figura 51), se consideră un filtru Kalman extins, care propagă între iterații densitatea de probabilitate a ipotezei (EKF-PHD). În jurul ciclului 50, valoarea OSPA (Figura 51, sus) se deteriorează datorită apropierii traiectoriilor obiectelor marcate cu verde și cu albastru. Acest lucru devine mai evident atunci când se utilizează M-OSPA cu factor de formă (Figura 51, jos). Deficiențele la inițializare în intervalul $[0, 10]$ sunt vizibile mult mai clar în figurile de jos ale tuturor filtrelor investigate, deoarece valorile OSPA reprezentate în figurile de sus iau în considerare doar eroarea de localizare, nu și pe cea de cardinalitate.

În cazul 2 (Figura 52) se consideră un filtru Kalman extins, cu propagarea între iterații a intensității statistice (EKF-CPHD). Se poate observa că performanța acestuia de a estima numărul total de ținte depășește semnificativ pe cea a filtrului din cazul 1, EKF-PHD. Valorile M-OSPA la ciclurile 20, 40 și 80 - atunci când apar și dispar obiecte în zona de acoperire a senzorului - sunt mult mai mici în Figura 52, comparativ cu cele din Figura 51. În general, algoritmul de tracking EKF-CPHD în culoarea cyan are o performanță remarcabilă, în ceea ce privește erorile de inițializare, estimarea cardinalității, erorile de localizare și numărul de nepotriviri. După cum s-a demonstrat analitic și prin simulări și în [95], comparația valorilor M-OSPA pentru filtrul EKF-CPHD, respectiv EKF-PHD, în jurul ciclului 20 evidențiază

superioritatea EKF-CPHD în determinarea corectă, însă cu o mică întârziere a numărului real al obiectelor de interes.




Figura 51: Filtrul EKF-PHD, sus: eroare de localizare OSPA, jos: eroare de localizare M-OSPA cu factor de formă; Σ_{Y1} în negru, Σ_{Y2} în roșu, Σ_{Y3} în albastru, Σ_{Y4} în cian. Timpul este exprimat în cicluri radar.

În cazul 3 (Figura 53) este evaluată performanța de aproximare a densității multi-țintei, utilizând filtrul secvențial multi-Bernoulli cu cardinalitate echilibrată (SMC-CB-MB). Estimarea cardinalității este acceptabilă, cu valori M-OSPA la ciclurile 20, 40 și 80 aflate între valorile corespunzătoare filtrelor EKF-PHD, respectiv EKF-CPHD.

Cu toate acestea, performanța relativ modestă în faza de inițializare între [0, 10] cicluri radar este evidentă. Datorită limitării impuse de numărul total de particule utilizabile, în scanarea zonei de acoperire, și a procedurii de eșantionare intrinsecă aplicată de algoritmul SMC prezentat în subcapitolul 5.6.3, performanța de localizare a SMC-CB-MB este, de asemenea, relativ slabă. Eșantionarea intrinsecă este necesară pentru limitarea numărului de particule necesar pentru testarea zonelor în care apar ținte noi. Deoarece fiecare țintă nouă care apare în zona de acoperire necesită un număr suplimentar de particule pentru localizare, și în consecință un număr de particule care poate crește nelimitat între diferitele iterații ale unui radar, este nevoie de un mecanism de selecție al particulelor principale, cu ponderile cele mai mari din setul de particule cu număr maxim limitat, pe principiul "supraviețuiește cel mai puternic".

În concluzie, prin aplicarea metricii M-OSPA, se poate observa că dintre cele trei cazuri luate în considerare, al doilea algoritm care folosește filtrul Kalman extins

cu propagarea densității cardinalizate a ipotezei de probabilitate (EKF-CPHD) le depășește pe restul, având cea mai mică eroare de localizare.




Figura 52: Filtrul EKF-CPHD, sus: eroare de localizare OSPA, jos: eroare de localizare M-OSPA cu factor de formă; Σ_{Y1} în negru, Σ_{Y2} în roșu, Σ_{Y3} în albastru, Σ_{Y4} în cian. Timpul este exprimat în cicluri radar.




Figura 53: Filtrul SMC-CB-MB, sus: eroare de localizare OSPA, jos: eroare de localizare M-OSPA cu factor de formă; Σ_{Y1} în negru, Σ_{Y2} în roșu, Σ_{Y3} în albastru, Σ_{Y4} în cian. Timpul este exprimat în cicluri radar.

În continuare, este considerat un al doilea scenariu cu trei vehicule, care se deplasează într-o situație de trafic cu intersecții, așa cum se poate observa în Figura 54. Vehiculele intră în zona de acoperire a senzorului de referință, la momentele de timp 0, 10, respectiv 20 și îl părăsesc la momentele de timp 70, 80 și 100, după cum se arată în Figura 55. Când apar noi ținte, ne așteptăm ca algoritmi de urmărire să necesite câteva iterații, până când detectează, localizează și clasifică acele noi ținte. Potențiale nepotriviri sunt posibile în jurul ciclului radar 40, când traiectoriile mașinilor B și C se intersectează, și în jurul ciclului radar 60, atunci când traiectoriile mașinilor A și C se încrucișează (Figura 55).




Figura 54: Simularea a trei ținte (mașina A-verde, B-albastru, respectiv C-cyan) într-un scenariu cu intersecții. Cercurile indică locul în care țintele apar în câmpul de acoperire, iar triunghiurile indică locul în care țintele dispar. Axele în [cm].

Cele trei autoturisme se deplasează pe o suprafață cu lungimea de 40 de metri și lățimea de 20 de metri, fără a lua în considerare eventuale denivelări sau înclinări ale carosabilului. Modelele de mișcare selectate (vezi subcapitolul 4.1.3) sunt mișcare cu viteză constantă, pentru autoturismele A și C, respectiv cu rată de curbură constantă, pentru autoturismul B. Toate cele trei autoturisme au viteze relativ reduse, sub 40km/h. Datorită concentrației mari de puncte de interes, corespunzătoare reprezentării extinse ale țintelor considerate, momentele de intersecție între autovehiculele aflate în mișcare sunt greu de procesat corect de către radarele îmbarcate și reprezintă în consecință situații de interes deosebit. În plus, perioadele de inițializare ale traiectoriilor noi și intervalele de timp adiacente momentelor de apariție, respectiv de dispariție, a mașinilor în zona de acoperire a senzorului de referință vor fi studiate în detaliu.

Din nou se vor analiza cele trei cazuri: filtrul Kalman extins, care propagă între iterații densitatea de probabilitate a ipotezelor (EKF-PHD), filtrul Kalman extins, cu propagarea între iterații a densității cardinalizate a intensității statistice (EKF-CPHD) și filtrul de aproximare a densității multi-țintei utilizând algoritmul secvențial multi-Bernoulli cu cardinalitate echilibrată (SMC-CB-MB).

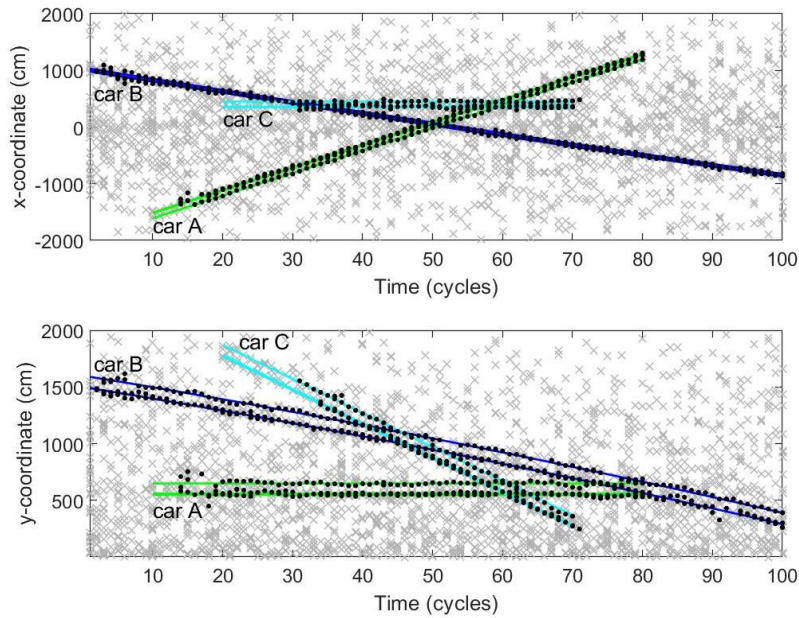


Figura 55: Trei ținte cu intersecții, sus: poziția x, jos: poziția y pentru fiecare punct reprezentativ (punctul cel mai la stânga, cel mai apropiat și cel mai la dreapta) per țintă. Timpul este exprimat în cicluri radar.




Figura 56: Filtru EKF-PHD, scenariul 2, sus: eroare de localizare OSPA, jos: eroare de localizare M-OSPA cu factor de formă; Σ_{Y_1} în negru, Σ_{Y_2} în roșu, Σ_{Y_3} în albastru, Σ_{Y_4} în cian. Timpul este exprimat în cicluri radar.

Filtrul EKF-PHD din Figura 56 are o performanță bună în faza de inițializare în intervalul $[0, 10]$ cicluri radar. Efectul lipsei detecțiilor, atunci când mașinile A respectiv C, intră în zona de acoperire a radarului este vizibil numai în graficul corespunzător M-OSPA (Figura 56 jos). Erorile relativ reduse de localizare, asociate traiectoriei mașinii B, care apar în jurul ciclului 95 sunt amplificate în mod neintuitiv de către metrica OSPA standard (Figura 56 sus), însă sunt aplatizate în graficul corespunzător M-OSPA (Figura 56 jos).

Filtrul EKF-CPHD din Figura 57 este mai performant decât EKF-PHD, atunci când apar ținte noi, la momentele de timp asociate ciclurilor radar 10 și 20. Un efect interesant poate fi observat atât în variația OSPA, cât și în variația M-OSPA în intervalul $[55, 65]$ de cicluri radar, atunci când traiectoriile mașinilor A și C se intersectează. Maximele locale ale OSPA, precum și ale M-OSPA apar în acest interval, pentru fiecare dintre cele trei puncte reprezentative ale țintei extinse (cel mai din stânga, cel mai apropiat și cel mai din dreapta). Avantajul utilizării M-OSPA în comparație cu OSPA este de asemenea vizibil în jurul ciclului radar 75, unde mașinile A și B se mișcă pe traiectorii îndepărtate, care nu ar trebui să conducă la o eroare semnificativă de localizare.




Figura 57 Filtru EKF-CPHD, scenariul 2, sus: eroare de localizare OSPA, jos: eroare de localizare M-OSPA cu factor de formă; Σ_{Y_1} în negru, Σ_{Y_2} în roșu, Σ_{Y_3} în albastru, Σ_{Y_4} în cyan. Timpul este exprimat în cicluri radar.

Inițializarea lentă a filtrului SMC-CB-MB din Figura 58 este caracteristică reprezentării prin particule a densității ipotezei de probabilitate pentru multi - ținte.

Precizia de localizare, determinarea cardinalității și capacitatea de evitare a nepotrivirilor sunt relativ bune, în cazul acestui grup de filtre.

În cadrul celui de-al doilea scenariu analizat, presupunând că inițializarea relativ lentă este acceptabilă, filtrul SMC-CB-MB oferă cea mai bună performanță, având cea mai mică eroare M-OSPA.




Figura 58: Filtrul SMC-CB-MB, scenariul 2, sus: eroare de localizare OSPA, jos: eroare de localizare M-OSPA cu factor de formă; Σ_{Y1} în negru, Σ_{Y2} în roșu, Σ_{Y3} în albastru, Σ_{Y4} în cyan. Timpul este exprimat în cicluri radar.

Rezultatele simulărilor ambelor scenarii arată că metrica M-OSPA cu factor de formă poate fi folosită cu succes remarcabil și într-un mod eficient pentru a identifica cel mai performant tracker de multi - obiecte dintr-un set dat de algoritmi.

6 CONCLUZII

Teza prezintă metode analitice noi pentru evaluarea gradului de performanță a algoritmilor de urmărire a țintelor multiple din traficul rutier și rezultate experimentale care demonstrează utilitatea practică a metodelor propuse. Metodele pot fi folosite în diverse aplicații tehnice, în special în funcțiile de urmărire și protecție a pietonilor, care au de regulă un model dinamic cu un număr relativ mare ($L > 4$) de puncte reprezentative. Metodele propuse sunt deja utilizate parțial pentru validarea sistemelor radar Gen5, dezvoltate și produse de către compania Veoneer, imbarcate în autoturismele Mercedes-Benz de ultimă generație.

Evoluția tehnologică a sistemelor radar de detecție și urmărire a țintelor aflate în zona de acoperire permite în prezent o reprezentare detaliată a obiectelor de interes. Spre deosebire de primele generații de radare automotive, în care fiecare obiect detectat era reprezentat în modelul intern de percepție printr-un singur punct caracteristic, radarele moderne pot estima nu doar centrul de masă al fiecărei ținte, ci și distribuția exactă a acestuia în spațiu. Date suplimentare cum ar fi lățimea, lungimea, conturul sau orientarea unghiulară corespunzătoare unui autoturism sau pieton pot fi colectate cu o precizie dependentă de condițiile de mediu și de parametri tehnici de operare ai radarului, cum ar fi de exemplu temperatura internă a acestuia sau tensiunea de alimentare a interfeței analogice de radio-frecvență. Reprezentarea extinsă a țintelor multiple conduce la probleme noi în evaluarea nivelului de performanță a sistemelor de tracking. Atât starea reală în spațiul multidimensional corespunzătoare unui obiect, cât și starea estimată sunt reprezentate printr-un număr ridicat de puncte caracteristice, comparația între percepție și realitate devenind astfel mai dificilă.

Capitolul 1

Acest capitol este o introducere în principiul de funcționare a sistemelor radar imbarcate pe autoturisme. Inițial sunt prezentate atât tipurile diferite de senzori utilizați de regulă în mașini, cât și avantajele și dezavantajele relative între sistemele radar, lidar și camere video. În continuare, sunt enumerate categoriile diferite de radare automotive și câteva funcții uzuale ale acestora. Nu doar capacitatea remarcabilă de percepție a radarelor de ultimă generație ci și raportul preț / performanță deosebit de atractiv poziționează tehnologia radar în fruntea echipamentelor necesare pentru evoluția graduală spre nivelul maxim L5 de autonomie automotive, atunci când mașinile pot naviga complet autonom, fără intervenția vreunui conducător auto.

Capitolul 2

O primă *contribuție personală* este dată de prezentarea în Capitolul 2 a principiului de funcționare și ale bazelor teoretice ale unui radar automotive, autorul studiind atât vasta literatură de specialitate menționată în bibliografie, cât și utilizând experiența personală acumulată într-un proiect de dezvoltare în cadrul companiei Continental. Sunt discutate categoriile de radare rezultate în funcție de raza de acoperire și unghiul de apertură. Principiul Doppler de măsură permite determinarea vitezei radiale relative între o țintă urmărită și ego-vehicul, respectiv automobilul pe care este imbarcat radarul de referință. În plus, un radar permite determinarea

distanței dintre poziția sa de referință și fiecare țintă în parte și a orientării unghiulare corespunzătoare fiecărei ținte.

Principiul de procesare numerică a semnalului FMCW recepționat este prezentat în detaliu, evidențiindu-se necesitatea de a efectua un număr relativ mare de transformate Fourier rapide (FFT). Acest lucru implică acceleratoare hardware specializate în calculul FFT, integrate în procesorul numeric de semnal radar. În continuare sunt prezentate cerințele relevante pentru dimensionarea memoriei de date a procesorului, pentru a putea stoca cubul de date radar.

Protecția participanților vulnerabili la trafic, de exemplu a pietonilor sau a bicicliștilor, are o importanță deosebită. Pentru detecția pietonilor, se urmărește identificarea amprentelor biometrice cauzate de bătăile inimii sau de micro-mișcări ale brațelor și picioarelor. Principiul Doppler utilizat pentru ținte de dimensiuni relativ mari, de exemplu mașini sau camioane, nu mai poate fi aplicat cu succes în acest caz. Prin utilizarea efectului micro-Doppler descris în acest capitol este posibilă detecția și localizarea pietonilor, bicicliștilor sau chiar a unor animale care traversează șoseaua.

Capitolul 3

În cadrul unei noi *contribuții personale* din capitolul 3, sunt prezentate și apreciate critic tehnicile de procesare digitală a semnalelor radar. Semnalul de recepție conține informații utile atât în amplitudine, cât și în fază și trebuie considerat în lanțul de procesare ca și un semnal complex. Sunt descrise componentele hardware și software utilizate în procesarea semnalelor radar. Una din etapele finale a lanțului de procesare este cea de urmărire în timp a țintelor de interes. Algoritmii de tracking utilizați în mod frecvent până în prezent necesită o asociere a detecțiilor prelevate la fiecare ciclu radar unor obiecte considerate ca fiind existente și menținute în memoria procesorului într-o listă dinamică de ținte ipotetice. Etapa de asociere este una în care se pierde o parte din informația disponibilă la receptor și care de multe ori induce erori suplimentare. Pentru a evita acest dezavantaj, teza propune utilizarea unei familii noi de algoritmi de tracking și anume filtrele cu propagare a momentului statistic de ordin întâi al densității de probabilitate, PHD. Aceste filtre consideră toate țintele detectate la un moment dat ca fiind o singură multi-țintă cu caracteristici statistice corespunzătoare.

După prima respectiv a doua transformare FFT, se obțin valorile pentru distanță și viteză relativă. Stabilirea poziției unghiulare necesită prelucrarea simultană a ecoului radar prelevat de către mai multe antene de recepție, poziționate la multipli întregi ai jumătății lungimii de undă a semnalului purtător. Pentru îmbunătățirea rezoluției unghiulare și în consecință a separabilității între obiecte învecinate, se pot cascada mai multe interfețe analogice de radio-frecvență, obținându-se astfel un număr mai mare de canale de recepție.

Limita de detecție a țintelor permite separarea semnalului util de zgomot și semnale perturbatoare. Pentru a eficientiza consumul de resurse hardware necesare pentru etapa de detecție, această limită CFAR trebuie adaptată dinamic în funcție de forma semnalelor recepționate și de numărul de ținte.

O mare parte a eșantioanelor semnalului de la receptor sunt sub limita de detecție și pot fi eliminate din etapele ulterioare de procesare. Stabilirea suportului sparse a acestor semnale, deci a regiunilor de frecvență în care este concentrată energia utilă a semnalului, are o importanță centrală în compresia datelor. Arhitecturile noi ale rețelelor electronice din autoturisme consideră centralizarea procesării semnalelor radar provenite de la mai mulți senzori. Astfel, senzorii din generațiile următoare vor transmite semnale puțin procesate (post conversie analog-digitală, eventual după prima transformare FFT) pe magistrale de date de viteză înaltă, de

exemplu 1Gbit Ethernet. Metodele de compressive sensing analizate ca și *contribuție personală* în această teză și publicate în [26] permit reducerea considerabilă a volumului de date utile, fără pierderi semnificative de informație. Modelele matematice și rezultatele experimentale corespunzătoare sunt prezentate și discutate în detaliu în acest capitol.

Capitolul 4

Capitolul 4 se concentrează pe algoritmi uzuali de urmărire a țintelor. Modelele de observație, respectiv de mișcare a țintelor, sunt analizate în detaliu, stabilind astfel baza teoretică pentru rezultatele experimentale prezentate în capitolul 5. Filtrele Kalman și Kalman extins sunt prezentate succint, fiind considerate cunoscute și având un număr remarcabil de publicații descriptive.

Modelarea matematică a obiectelor cu reprezentare extinsă este discutată ca și *contribuție personală* la finalul acestui capitol, fiind publicată anterior de către autor în [65].

Capitolul 5

Capitolul 5 este dedicat metodelor de evaluare a gradului de performanță a algoritmilor de urmărire a țintelor multiple. Și în acest capitol, *contribuția personală* începe prin clasificarea și aprecierea critică a metricilor uzuale, folosite în prezent pentru validarea algoritmilor de tracking. Setul de metrici CLEAR este relativ simplu și poate fi calculat cu efort computațional redus. Dezavantajele principale ale acestuia constau în capacitatea slabă de identificare a confuziilor și în invarianța acurateței de localizare relativ la durata intervalului de timp în care persistă aceste confuzii. Metrica OSPA combină valorile pentru acuratețe și precizie din setul CLEAR și elimină dezavantajele de mai sus legate de situațiile cu confuzii.

Această teza propune ca și o nouă *contribuție personală* utilizarea distanței Mahalanobis ca și distanță de bază în calculul OSPA, metodă propusă în [64]. Distanța Mahalanobis permite integrarea gradului de incertitudine în evaluarea performanței algoritmilor de tracking. Astfel, prin utilizarea distanței M-OSPA se pot distinge diferențele de performanță între algoritmi cu valori medii identice pentru distanță, viteză relativă și poziție unghiulară, dar cu parametri statistici diferiți. Următoarea *contribuție personală*, prezentată de asemenea în acest capitol, introduce o metodă eficientă de calcul al valorii M-OSPA pentru scenarii cu ținte multiple care au fiecare o reprezentare extinsă, deci cu mai multe puncte caracteristice per țintă. Metoda introdusă permite o reducere a timpului de procesare cu aproximativ 20%.

Variantele majore ale algoritmilor de tracking PHD sunt prezentate în detaliu. În plus este discutat și ulterior utilizat în partea de simulări filtrul multi-Bernoulli cu cardinalitate echilibrată pentru multi-ținte, CB-MB. Avantajele și limitările fiecărui filtru sunt discutate în subcapitolele corespunzătoare.

Ultima *contribuție personală* este dată de un set amplu de simulări și rezultate experimentale, publicate în [63]. Acesta demonstrează că metrica M-OSPA cu factor de formă poate fi folosită cu succes remarcabil și într-un mod eficient pentru a identifica cel mai performant tracker de multi – obiecte dintr-un set dat de algoritmi.

Capitolul 6

Capitolul 6 conține concluziile tezei de doctorat. El rezumă capitolele anterioare și subliniază contribuțiile personale aduse de autor în această lucrare.

7 BIBLIOGRAFIE

- [1] A. Kapp, „Ein Beitrag zur Verbesserung und Erweiterung der Lidarsignalverarbeitung für Fahrzeuge,“ Uni Karlsruhe, 2007.
- [2] N. Kämpchen, „Feature-Level Fusion of Laser Scanner and Video Data for Advanced Driver Assistance Systems,“ Universität Ulm, 2007.
- [3] S. Pietzsch, „Modellgestützte Sensordatenfusion von Laserscanner und Radar zur Erfassung komplexer Fahrzeugumgebungen,“ Technische Universität München, 2015.
- [4] V. Viikari, M. Kantanen, T. L. A. Varpula, A. Alastalo, T. Mattila, H. Seppä și P. Pursula, „Technical Solutions for Automotive Intermodulation Radar for Detecting Vulnerable Road Users,“ 2009.
- [5] H. Yan et al., „Micro-doppler based classifying features for automotive radar VRU target classification,“ Detroit, Michigan, 2017.
- [6] Aspencore, Sensors in automotive, J. Joshida, Ed., Cambridge: Aspencore LLD, 2020.
- [7] S. Patole, M. Torlak, D. Wang și M. Ali, „Automotive Radars: A review of signal processing techniques,“ *IEEE Signal Processing Magazine*, pp. 22-35, March 2017.
- [8] M. A. Richards, J. A. Scheer și W. A. Holm, Principles of Modern Radar, Raleigh: Scitech Publishing, 2010.
- [9] G. M. Brooker, "Understanding Millimetre Wave FMCW Radars," in *1st International Conference on Sensing Technology*, Palmerston North, New Zealand, 2005.
- [10] V. C. Chen, The Micro-Doppler Effect in Radar, Artech House, 2011.
- [11] C. P. Lai, Q. Ruan și R. M. Narayanan, „Hilbert-Huang Transform (HHT) processing of wall noise radar data for human activity characterization,“ în *Proc. IEEE SAFE 2007 Workshop on Signal Processing Applications for Public Security and Forensics*, Washington D.C., 2007.
- [12] T. Thayaparan, L. Stankovic, I. Djurovic, S. Penamati și V. Kamiseti, „Intelligent target recognition using micro-Doppler radar signatures,“ în *Proceedings of SPIE - The International Society for Optical Engineering*, 2009.
- [13] L. Bansod, B. A. S. și A. Ghosh, „Application of MUSIC Algorithm for Adaptive Beamforming Smart Antenna,“ *International Research Journal of Engineering and Technology*, vol. 4, nr. 3, p. 381/384, 2017.
- [14] R. O. Schmidt, „Multiple Emitter Location and Signal Parameter Estimation,“ *IEEE Transactions on Antennas and Propagation*, Vol. 34, nr. 3, 1986.
- [15] C. Li, G. Liao, S. Zhu și S. Wu, „An ESPRIT-like algorithm for coherent DOA estimation based on data matrix decomposition in MIMO radar,“ *Signal Processing*, vol. 91, nr. 8, pp. 1803-1811, 2011.
- [16] J. Cooley și J. Tukey, „An Algorithm for the Machine Computation of Complex Fourier Series,“ *Mathematics of Computation*, vol. 19, p. 297–301, 1965.

- [17] N. Levanon, *Radar Principles*, New York: John Wiley and Sons, 1988.
- [18] H. Finn și R. Johnson, „Adaptive Detection Mode with Threshold Control as a Function of Spatially Sampled Clutter-Level Estimates,” *RCA Review*, vol. September, p. 414–464, 1968.
- [19] S. Kay, *Fundamentals for Statistical Signal Processing*, vol. 1: Estimation Theory, Englewood Cliffs: Prentice Hall, 1993.
- [20] H. Rohling, „Radar CFAR Thresholding in Clutter and Multiple Target Situations,” *Transactions on Aerospace and Electronic Systems IEEE*, vol. AES-19, no. 4, p. 608–621, July 1983.
- [21] H. Rohling, „New CFAR-Processor Based on an Ordered Statistic,” în *Proceedings of the IEEE International Radar Conference*, Arlington, 1985.
- [22] P. Gandhi și S. Kassam, „Analysis of CFAR Processors in Nonhomogeneous Background,” *IEEE Transactions on AES*, vol. 24, nr. 4, 1988.
- [23] H. Rohling et al., „The ARTRAC Architecture,” [Interactiv]. Available: http://artrac.org/file.php/ARTRAC_Architecture.pdf-2012-10-16. [Accesat 19 6 2014].
- [24] A. Macaveiu, C. Nafornta, A. Isar, A. Campeanu și I. Nafornta, „A method for building the range-Doppler map for multiple automotive radar targets,” în *11th International Symposium on Electronics and Telecommunications (ISETC)*, Timisoara, 2014.
- [25] A. Macaveiu, A. Campeanu și I. Nafornta, „Kalman-Based Tracker for Multiple Radar Targets,” 2014.
- [26] C. Nafornta, A. Isar și T. Dehelean, „Comparison of Two Compressive Sensing Algorithms for Automotive Radar,” în *International Symposium on Electronics and Telecommunications*, Timisoara, 2020.
- [27] C. Nafornta și A. Isar, *Signals and systems*, Vol. 2., Ed. Politehnica, ISBN 978-973-625-942-5, 2016.
- [28] E. Candès, J. Romberg și T. Tao, „Stable signal recovery from incomplete and inaccurate measurements,” *Communications on Pure and Applied Mathematics*, 59 (8), p. 1207–1223, 2006.
- [29] Y. C. Eldar, *Sampling Theory: Beyond Bandlimited Systems*, Cambridge University Press, April 2015.
- [30] R. G. Baraniuk, „Compressive Sensing [Lecture Notes],” *IEEE Signal Processing Magazine*, vol. 24, nr. 4, pp. 118-121, July 2007.
- [31] E. Candès și J. Romberg, l1-MAGIC: Recovery of Sparse Signals via Convex Programming,, pp. 1-19, 2005.
- [32] P. Knee, *Sparse Representations for Radar with MATLAB Examples*, Morgan & Claypool., 2012.
- [33] M. Schmid, „Umgebungserfassung für Fahrerassistenzsysteme mit hierarchischen Belegungskarten,” Universität der Bundeswehr, München, 2012.
- [34] C. Yixin, M. Das și D. Bajpai, „Improving time-to-collision estimation by imm based kalman filter,” în *SAE World Congress & Exhibition*, 2009.
- [35] M. Richards, *Fundamentals of Radar Signal Processing*, New York: McGraw-Hill, 2005.

- [36] X. R. Li și V. Jilkov, „Survey of maneuvering target tracking: Part I. Dynamic models,” *IEEE Transactions on Aerospace and Electronic*, p. 1333–1364, October 2003.
- [37] Y. Bar-Shalom, X. R. Li și T. Kirubarajan, *Estimation with Applications to Tracking and Navigation: Theory, Algorithms, and Software*, New York: Wiley, 2001.
- [38] H. Lee și M.-J. Tahk, „Generalized input-estimation technique for tracking,” *IEEE Transactions on Aerospace and Electronic Systems*, 35, p. 1388–1402, 1999.
- [39] R. A. Singer, „Estimating optimal tracking filter performance for manned maneuvering targets,” *Transactions on Aerospace and Electronic Systems*, AES-6, nr. 4, p. 473–483, 1970.
- [40] R. A. Singer și K. W. Behnke, „Real-time tracking filter evaluation and selection for tactical applications,” *IEEE Transactions on Aerospace and Electronic Systems*, AES-7, nr. 1, p. 100–110, 1971.
- [41] J. P. Helferty, „Improved tracking of maneuvering targets: The use of turn-rate distributions for acceleration modeling,” *Transactions on Aerospace and Electronic Systems*, 32, vol. 4, p. 1355–1361, 1996.
- [42] R. A. Howard, „System analysis of semi-Markov processes,” *IEEE Transactions Military Electronics*, MIL-8, p. 114–124, 1964.
- [43] R. L. Moose și P. L. Wang, „An adaptive estimator with learning for a plant containing semi-Markov switching parameters,” *IEEE Transactions on Systems, Man, Cybernetics*, SMC-3, p. 277–281, 1973.
- [44] X. R. Li și Y. Bar-Shalom, „Design of an interacting multiple model algorithm for air traffic control tracking,” *IEEE Transactions on Control Systems Technology*, vol. 1, nr. 3, p. 186–194, 1993.
- [45] F. Dufour și M. Mariton, „Passive sensor data fusion and maneuvering target tracking,” *Multitarget-Multisensor Tracking: Applications and Advances*, Vol. II, p. capitolul 3, 1992.
- [46] F. Dufour și M. Mariton, „Tracking a 3D maneuvering target with passive sensors,” *Transactions on Aerospace and Electronic Systems*, vol. 27, nr. 4, p. 725–739, 1991.
- [47] F. Gustafsson, *Adaptive Filtering and Change Detection*, New York: Wiley, 2001.
- [48] R. Mehra, „Approaches to adaptive filtering,” în *IEEE Transactions on Automatic Control*, 1972.
- [49] F. Gustafsson și A. J. Isaksson, „Best choice of state variables for tracking coordinated turns,” în *Proceedings of the 35th IEEE Conference on Decision and Control*, Kobe, Japan, 1996.
- [50] J. L. Gertz, „Multisensor surveillance for improved aircraft tracking,” *Lincoln Laboratory Journal*, vol. 2, nr. 3, p. 381–396, 1989.
- [51] M. Busch și S. Blackman, „Evaluation of IMM filtering for an air defence system application,” în *Proceedings of the 1995 SPIE Conference on Signal and Data Processing of Small Targets*, 1995.

- [52] S. Blackman, M. Busch și R. F. Popoli, „IMM/MHT solution to radar benchmark tracking problem,” în *Transactions on Aerospace and Electronic Systems*, 1999.
- [53] S. Saponara, M. Greco, E. Ragonese, G. Palmisano și B. Neri, *Highly Integrated Low-Power Radars*, Norwood: Artech House, 2014.
- [54] R. Kalman, „A new approach to linear filtering and prediction problems,” *Transactions of the ASME–Journal of Basic Engineering*, p. 35–45, 1960.
- [55] J. B. Pearson și E. B. Stear, „Kalman filter applications in airborne radar tracking,” în *Transactions on Aerospace and Electronic Systems*, 319–329, 1974.
- [56] M. I. Ribeiro, „Kalman and extended kalman filters: Concept, derivation and properties,” Institute for Systems and Robotics, Lisabon, 2004.
- [57] S. J. Julier și J. K. Uhlmann, „A new extension of the kalman filter to nonlinear systems,” în *Proc. SPIE Signal Processing, Sensor Fusion, and Target Recognition VI*, 1997.
- [58] F. Gustafsson, F. Gunnarsson, N. Bergman, U. Forssell și e. al., „Particle Filters for Positioning, Navigation and Tracking,” *IEEE Transactions on Signal Processing, Special Issue on Monte Carlo Methods for Statistical Signal Processing*, vol. 50, nr. 2, pp. 425 - 437, 2002.
- [59] M. Connor, K. Haas și A. Volfson, „Multiple Target Tracking,” January, 2008.
- [60] K. Granstrom, M. Baum și S. Reuter, „Extended Object Tracking: Introduction, Overview and Applications,” *Journal of Advances in Information Fusion*, vol. 12, no. 2, pp. 139-174, Dezember 2017.
- [61] D. Li, K. D. Wong, Y. H. Hu și A. M. Sayeed, „Detection, Classification and Tracking of Targets,” *IEEE SIGNAL PROCESSING MAGAZINE*, pp. 17-29, March 2002.
- [62] F. Bashir și F. Porikli, „Performance Evaluation of Object Detection and Tracking Systems,” MITSUBISHI ELECTRIC RESEARCH LABORATORIES, Cambridge, Massachusetts, 2006.
- [63] T. Dehelean, C. Nafornita și A. Isar, „Enhanced metric for multiple extended object tracker,” *Revue Roumaine des Sciences Techniques - Serie Électrotechnique et Énergétique*, vol. 65, nr. 3-4, pp. 235 - 243, 2020.
- [64] T. Dehelean, C. Nafornita și A. Isar, „Estimate’s Statistics in the Performance Evaluation of Extended Object Tracker,” în *2019 International Symposium on Signals, Circuits & Systems (ISSCS)*, Iasi, 2019.
- [65] T. Dehelean, C. Nafornita și A. Isar, „OSPA Metric for Radar Extended Object Tracker,” în *2018 International Symposium on Electronics and Telecommunications (ISETC)*, Timisoara, 2018.
- [66] R. Lindl, „Tracking von Verkehrsteilnehmern im Kontext von Multisensorsystemen,” Technische Universität München, 2009.
- [67] M. Skutek, „Ein PreCrash-System auf Basis multisensorieller Umgebungserfassung,” Technische Universität, Chemnitz, 2006.
- [68] L. Walchshäusl, „Maschinelle Erkennung von Verkehrsteilnehmern mittels heterogener Sensorik,” Technische Universität München, 2008.

- [69] T. D. Vu, „Vehicle Perception: Localization, Mapping with Detection, Classification and Tracking of Moving Objects,” Institut National Polytechnique, Genoble, 2009.
- [70] K. Bernardin și R. Stiefelhagen, „Evaluating Multiple Object Tracking Performance: The CLEAR MOT Metrics,” *EURASIP Journal on Image and Video Processing*, pp. 1-10, 2008.
- [71] M. M. Deza și E. Deza, *Encyclopedia of distances*, Springer Berlin Heidelberg, 2009.
- [72] J. R. Hoffman și R. P. S. Mahler, „Multitarget miss distance via optimal assignment,” *IEEE Transactions on Systems, Man, and Cybernetics - Part A: Systems and Humans*, vol. 34, no. 3, pp. 327-336, May 2004.
- [73] D. Schuhmacher, B. T. Vo și B. N. Vo, „A Consistent Metric for Performance Evaluation of Multi-Object Filters,” *IEEE Trans. Signal Processing*, vol. 56, no. 8, pp. 3447-3457, 2008.
- [74] B. Ristic, B. N. Vo, D. Clark și B. T. Vo, „A Metric for Performance Evaluation of Multi-Target Tracking Algorithms,” *IEEE TRANS. SIGNAL PROCESSING*, VOL. 59, NO. 7, pp. 3452-3457, 2011.
- [75] S. Nagappa, D. E. Clark și R. Mahler, „Incorporating track uncertainty into the OSPA metric,” în *14th Int. Conf. on Information Fusion*, Chicago, IL, 2011.
- [76] A. S. Rahmathullah, Á. F. García-Fernández și L. Svensson, „Generalized optimal sub-pattern assignment metric,” în *20th International Conference on Information Fusion*, 2017.
- [77] D. F. Crouse, P. Willett, M. Guerriero și L. Svensson, „An approximate Minimum MOSPA estimator,” în *IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*, Prague, Czech Republic, 2011.
- [78] J. Bento, „A metric for sets of trajectories that is practical and mathematically consistent,” în *arXiv preprint arXiv:1601.03094*, 2016.
- [79] P. Mather și B. Tso, *Classification Methods for Remotely Sensed Data*, Second Edition. Environmental engineering.: Taylor & Francis, 2009.
- [80] H. W. Kuhn, „The Hungarian Method for the assignment problem,” *Naval Research Logistics Quarterly*, vol. 2, p. 83-97, 1955.
- [81] B. T. Vo, „Matlab toolbox for Random Finite Set,” 2019. [Interactiv]. Available: <http://ba-tuong.vo-au.com/codes.html>.
- [82] S. Blackman și R. Popoli, *Design and Analysis of Modern Tracking Systems*, Artech House Publishers, 1999.
- [83] T. Fortmann și Y. Bar-Shalom, *Tracking and Data Association*, Academic Press, Inc., 1988.
- [84] Y. Bar-Shalom și T. Fortmann, *Tracking and Data Association*, Academic Press, Inc., 1988.
- [85] D. Musicki, R. Evans și S. Stankovic, „Integrated probabilistic data association (ipda), in Decision and Control,” în *Proceedings of the 31st IEEE Conference on, pages 3796-3798 vol.4*, 1992.
- [86] I. Goodman, R. Mahler și H. Nguyen, *Mathematics of Data Fusion*, Kluwer Academic Publishers, 1997.

- [87] M. Mählich, „Filtersynthese zur simultanen Minimierung von Existenz-, Assoziations- und Zustandsunsicherheiten in der Fahrzeugumfelderfassung mit heterogenen Sensordaten,“ Universität Ulm, 2009.
- [88] R. Mahler, „Multitarget Bayes filtering via first-order multitarget moments,“ *IEEE Trans. on Aerospace and Electronic Systems*, 39(4), p. 1152–1178, 2003.
- [89] S. Thrun, W. Burgard și D. Fox, „A probabilistic approach to concurrent mapping and localization for mobile robots,“ *Machine Learning and Autonomous*, p. 1–25, 1998.
- [90] S. Thrun, W. Burgard și D. Fox, Probabilistic Robotics (Intelligent Robotics and Autonomous Agents), The MIT Press, 2005.
- [91] S. o. A. Engineers, „SAE j3016 Levels of driving,“ 7 iunie 2019. [Interactiv]. Available: <https://www.sae.org/news/2019/01/sae-updates-j3016-automated-driving-graphic>. [Accesat 6 martie 2021].
- [92] A. Markov, Extension of the Limit Theorems of Probability Theory to a Sum of Variables Connected in a chain. Reprinted in Appendix B of: R. Howard. Dynamic Probabilistic Systems, Volume 1: Markov Chains, John Wiley and Sons, 1971.
- [93] B. N. Vo și W. K. Ma, „The Gaussian mixture probability hypothesis density filter,“ *IEEE Transactions on Signal Processing*, vol. 54, no. 11, p. 4091–4104, 11 2006.
- [94] B. Ristic, B. T. Vo, B. N. Vo și A. Farina, „A Tutorial on Bernoulli Filters: Theory, Implementation and Applications,“ *IEEE Trans. Signal Processing*, vol. 61, nr. 13, pp. 3406 - 3430, 2013.
- [95] B. T. Vo, B. N. Vo și A. Cantoni, „Analytic Implementations of the Cardinalized Probability Hypothesis Density Filter,“ *Signal Processing, IEEE Transactions on*, 55, p. 3553 – 3567, 2007.
- [96] B. Vo, S. Singh și A. Doucet, „Sequential Monte Carlo methods for multi-target filtering with random finite sets,“ *IEEE Trans. Aerospace and Electronic Systems*, vol. 41, nr. 4, p. 1224–1245, 2005.
- [97] S. Reuter, D. Meissner, B. Wilking și K. Dietmayer, „Cardinality balanced multi-target multi-Bernoulli filtering using adaptive birth distributions,“ *Proceedings of the 16th International Conference on Information Fusion, Istanbul*, pp. 1608-1615, 2013.
- [98] J. Effertz, „Autonome Fahrzeugführung in urbaner Umgebung durch Kombination objekt- und kartenbasierter Umfeldmodelle,“ Technische Universität Carolo-Wilhelmina, Braunschweig, 2009.
- [99] P. Matzka, A. Wallace și Y. Petillot, „Efficient resource allocation for automotive attentive vision systems,“ *IEEE Trans. on Intelligent Transportation Systems*, 13(2), p. 859–872, 2012.
- [100] S. Blackman, „Multiple hypothesis tracking for multiple target tracking,“ în *IEEE Aerospace and Electronic Systems Magazine*, 2004.