



**HAL**  
open science

# Combinaison d'estimations: application à la détection d'obstacles à bord des véhicules routiers intelligents

Christophe Blanc

► **To cite this version:**

Christophe Blanc. Combinaison d'estimations: application à la détection d'obstacles à bord des véhicules routiers intelligents. Automatique / Robotique. Université Blaise Pascal - Clermont-Ferrand II, 2005. Français. NNT: 2005CLF21549 . tel-00664762

**HAL Id: tel-00664762**

**<https://theses.hal.science/tel-00664762v1>**

Submitted on 31 Jan 2012

**HAL** is a multi-disciplinary open access archive for the deposit and dissemination of scientific research documents, whether they are published or not. The documents may come from teaching and research institutions in France or abroad, or from public or private research centers.

L'archive ouverte pluridisciplinaire **HAL**, est destinée au dépôt et à la diffusion de documents scientifiques de niveau recherche, publiés ou non, émanant des établissements d'enseignement et de recherche français ou étrangers, des laboratoires publics ou privés.

N° d'ordre : D. U : 1549  
EDSPIC : 321

**UNIVERSITE BLAISE PASCAL - CLERMONT II**

ECOLE DOCTORALE  
SCIENCES POUR L'INGENIEUR DE CLERMONT-FERRAND

**T h è s e**

Présentée par

**CHRISTOPHE BLANC**

pour obtenir le grade de

**DOCTEUR D'UNIVERSITÉ**

**SPECIALITE : VISION POUR LA ROBOTIQUE**

**Combinaison d'estimations : application à la détection d'obstacles à bord  
des véhicules routiers intelligents**

Soutenue publiquement le 12 juillet 2005 devant le jury :

M. J. Gallice  
M. D. Aubert  
M. J.P LeCadre  
M. R. Chapuis  
Y. Le Guilloux  
L. Trassoudaine

Président  
Rapporteur et examinateur  
Rapporteur et examinateur  
Examineur  
Examineur  
Directeur de thèse



# Résumé

Ces activités de recherche s'intègrent à l'un des deux groupes de recherche du laboratoire LAS-MEA : GRAVIR (GRoupe Automatique VIsion et Robotique), dont l'objectif est "de développer des concepts théoriques et méthodologiques pour la perception de l'environnement de machines, et de valider ceux-ci expérimentalement sur des démonstrateurs par des systèmes dédiés". Cet objectif a été particulièrement suivi dans les véhicules routiers intelligents puisque, depuis près de quinze ans, les résultats de recherches sur les capteurs, la reconnaissance des formes et la fusion de données obtenues par une dizaine de chercheurs sont appliqués à ce domaine. Ces recherches concernent la fusion de données pour la perception à bord des véhicules routiers intelligents. Elles s'inscrivent parmi deux projets : ARCOS (Action de Recherche pour une CONduite Sécurisée) s'inscrit dans le cadre des actions fédératives du PREDIT (Programme national de recherche et d'innovation dans les transports terrestres, à l'initiative des ministères chargés de la recherche, des transports, de l'environnement et de l'industrie, de l'Ademe et de l'Anvar) et PAROTO (Projet Anticollision Radar et Optronique pour l'auTOMobile) initié par le ministère de la recherche en partenariat avec SAGEM Division Défense et Sécurité, et l'INRETS (Institut National de REcherche sur les Transports et leur Sécurité). Dans ce cadre, je m'intéresse à un système de perception conduisant, et ceci dans une grande variété de situations, à la définition d'une carte de l'environnement à l'avant du véhicule intelligent : chaque obstacle y est décrit par sa position absolue, son état cinématique et un certain nombre de caractéristiques qui peuvent être déterminantes pour définir l'aide à apporter au conducteur. Cette perception s'appuie sur le développement d'un système de fusion de données appliqué à la détection et au suivi des obstacles. Plusieurs capteurs, dont les complémentarités et redondances ont été soulignées, ont ainsi été installés à l'avant de notre véhicule démonstrateur : VELAC (VEhicule du Lasmea pour l'Aide à la Conduite) ; un capteur RADAR (développé au sein de notre laboratoire) dont l'objectif prioritaire

est de fournir une information de vitesse relative des obstacles, un capteur LIDAR (Riegl) permettant une représentation 3D de la scène routière, un capteur thermique (SAGEM) dont l'objectif était de détecter et de suivre les différents obstacles quelques soient les conditions atmosphériques. Les données de ces différents capteurs sont traitées indépendamment afin de détecter, et de suivre les obstacles à l'avant du véhicule. La problématique de fusion est ainsi vue comme une combinaison de pistages (estimations à l'aide de filtre de Kalman ou à particules). Il devient donc possible, après cette fusion, de représenter une carte précise de l'environnement à l'avant du véhicule intelligent : chaque obstacle y est décrit par sa position absolue, et son état cinématique qui sont déterminants pour définir l'aide à apporter au conducteur. Des résultats ont été validés à bord de notre véhicule démonstrateur VELAC.

# Abstract

In road environment, road obstacles tracking is able to extract important information for driving safety. Indeed, kinematic characteristics estimation (relative position, relative speed, ...) provides a clearer road scene comprehension. This estimate is one of the important parameters of driver assistance systems. However, only one sensor generally does not allow to detect quickly (all the potentially dangerous obstacles) in all the directions, under all the atmospheric conditions. Moreover, the degree of obstacle recognition is different according to the sensor used. Multiplication of sensors makes it possible to face these various problems. Amalgamated information will represent entities in further details and with less uncertainty than with only one source. A system of higher level has been thus developed in order to have a robust management of all tracks and measurements coming from various sensors. This system, applied to various sensors measurements combination, gives important obstacles characteristics present in the front bumper of our experimental vehicle (VELAC : LASMEA's experimental vehicle for driving assistance). This state estimate is based on the use of various Bayesian methods (Extended Kalman Filter and Particle Filter). Here we will use the fusion of two obstacle tracking delivered by two independent systems : track to track fusion. These two systems propose estimates characterizing obstacles positions and relative speeds. Fusion estimation is based on the use of Extended Kalman filter (EKF) or particle filters.



# Table des matières

<b>Introduction</b>	<b>1</b>
<b>1 INTRODUCTION GENERALE</b>	<b>7</b>
1.1 La perception à bord des véhicules routiers intelligents . . . . .	7
1.1.1 Introduction . . . . .	7
1.1.2 Missions pour la perception de l'environnement routier . . . . .	11
1.1.3 Les véhicules intelligents : état de l'art non exhaustif . . . . .	13
1.1.3.1 Quelques plateformes expérimentales . . . . .	14
1.1.3.2 Les véhicules intelligents commercialisés . . . . .	18
1.1.4 Les différents projets du LASMEA . . . . .	21
1.1.4.1 le projet ARCOS . . . . .	21
1.1.4.2 le projet PAROTO . . . . .	22
1.1.4.3 le projet ROADSENSE . . . . .	24
1.2 Buts recherchés . . . . .	27
1.3 Estimation des caractéristiques cinématiques des obstacles . . . . .	30
1.4 Conclusion . . . . .	32
<b>2 DESCRIPTION DES CAPTEURS ET PRETRAITEMENT</b>	<b>33</b>
2.1 La télémétrie laser . . . . .	35



2.1.1	La place du laser dans les véhicules routiers intelligents . . . . .	35
2.1.2	Le télémètre laser LMSZ210-60 du LASMEA . . . . .	37
2.1.2.1	Le module de mesure de distance . . . . .	37
2.1.2.2	Le module de balayage . . . . .	39
2.1.2.3	Spécifications du capteur . . . . .	39
2.1.2.4	Définitions des axes . . . . .	39
2.1.2.5	Caractéristiques temporelles . . . . .	42
2.1.2.6	images 3D ou frames . . . . .	43
2.2	Le Radar . . . . .	48
2.2.1	La place du dans les véhicules routiers intelligents . . . . .	48
2.2.2	Radar Doppler à priorité Doppler du LASMEA . . . . .	50
2.2.2.1	Bilan de puissances . . . . .	50
2.2.2.2	Le signal Radar . . . . .	51
2.2.2.3	Mise en œuvre du Radar PAROTO . . . . .	54
2.3	Un exemple de caméra thermique : la caméra PAROTO (Sagem) . . . . .	56
2.4	La vision . . . . .	57
2.5	Complémentarités et redondances . . . . .	60
2.6	La détection d'obstacles : extraction des observations . . . . .	62
2.6.1	Extraction des observations laser . . . . .	62
2.6.1.1	Segmentation en régions de l'image 3D . . . . .	62
2.6.1.2	La reconnaissance des obstacles . . . . .	64
2.6.2	Extraction des observations Radar Doppler à priorité Doppler . . . . .	69
2.6.2.1	Extraction des mesures . . . . .	69
2.6.2.2	Regroupement des échos appartenant à la même cible . . . . .	72
2.6.2.3	Calcul des caractéristiques de la cible résultante des n échos associés . . . . .	72

---

2.6.2.4	Résultats . . . . .	73
2.6.3	Extraction des observations infrarouge . . . . .	75
2.6.4	Conclusion . . . . .	76
<b>3</b>	<b>ESTIMATION DE PARAMETRES</b>	<b>79</b>
3.1	Estimation de paramètres . . . . .	79
3.1.1	Les estimateurs . . . . .	81
3.1.1.1	Estimateurs à maximum de vraisemblance et à maximum a posteriori	81
3.1.1.2	Estimation des moindres carrés et minimisation du carré des erreurs	81
3.1.1.3	Estimateur non-biaisé . . . . .	82
3.1.1.4	Variance d'estimateur . . . . .	82
3.1.1.5	Borne de Cramer Rao et Matrice d'Information de Fisher . . . . .	83
3.1.2	Estimation linéaire et non linéaire . . . . .	84
3.1.2.1	Cas linéaire . . . . .	84
3.1.2.2	Cas non linéaire . . . . .	88
3.2	Cas des observations radar . . . . .	89
3.2.1	régression linéaire . . . . .	89
3.2.2	Observabilité pour le pistage radar en coordonnées cartésiennes à partir de coordonnées polaires . . . . .	92
3.2.3	Dynamique du véhicule routier . . . . .	93
3.2.3.1	Systèmes de coordonnées . . . . .	94
3.2.3.2	Dynamique longitudinale . . . . .	95
3.2.3.3	Dynamique latérale . . . . .	97
3.2.4	Modélisation de la route . . . . .	100
3.2.5	Estimation non linéaire . . . . .	101
3.2.5.1	Définition du problème . . . . .	102

3.2.5.2	Borne de Cramer Rao . . . . .	104
3.2.5.3	Estimation des paramètres de la trajectoire en virage . . . . .	106
3.3	Conclusion . . . . .	109
<b>4</b>	<b>LE SUIVI DES OBSTACLES</b>	<b>111</b>
4.1	Estimation récursive des caractéristiques de la piste . . . . .	112
4.1.1	Estimation bayésienne . . . . .	113
4.1.2	Filtre de Kalman . . . . .	115
4.1.3	Filtre à particules . . . . .	118
4.2	Performances des estimateurs récursifs : borne de Cramer Rao a posteriori . . . . .	124
4.2.1	Calcul récursif de la matrice d'information de Fisher . . . . .	124
4.2.1.1	Cas général . . . . .	124
4.2.1.2	Cas de Bruit gaussien . . . . .	125
4.2.1.3	Cas linéaire et gaussien . . . . .	126
4.2.1.4	Cas déterministe . . . . .	127
4.2.2	PCRB dans le cas linéaire : distribution beta et gaussienne . . . . .	127
4.2.2.1	Calcul de la borne . . . . .	127
4.2.2.2	Simulation : scénario en ligne droite . . . . .	130
4.2.3	PCRB dans le cas non linéaire . . . . .	131
4.2.3.1	Calcul de la borne . . . . .	133
4.2.3.2	Simulation : scénario en virage . . . . .	134
4.3	Gestion des pistes . . . . .	137
4.3.1	Association des pistes . . . . .	137
4.3.1.1	Fenêtrage . . . . .	138
4.3.1.2	Méthode du plus proche voisin (PPV) . . . . .	140

---

4.3.2	Initialisation et mort des pistes : vraies ou fausses pistes . . . . .	142
4.4	Application : simulation de suivi d'obstacles par Lidar et Radar . . . . .	143
4.4.1	Estimation par lidar . . . . .	143
4.4.1.1	scénario ligne droite . . . . .	145
4.4.1.2	scénario en virage . . . . .	146
4.4.2	Estimation par radar . . . . .	148
4.4.2.1	Estimation linéaire à partir des observations de distance et vitesse radiale . . . . .	148
4.4.2.2	Estimation non linéaire : scénario en virage . . . . .	149
4.5	Conclusion . . . . .	151
<b>5</b>	<b>LA FUSION PISTE A PISTE</b>	<b>153</b>
5.1	Architecture du système de fusion . . . . .	154
5.2	Gestion du flux de données . . . . .	156
5.2.1	monomode . . . . .	156
5.2.2	bimode . . . . .	156
5.3	Calcul des ressemblances . . . . .	156
5.4	La combinaison des pistes . . . . .	158
5.4.1	Consolidation bimode : filtre de kalman . . . . .	160
5.4.2	Consolidation : filtre à particule . . . . .	163
5.4.3	Validation ou divergence bimode . . . . .	166
5.5	Application : suivi d'obstacle en virage par fusion d'estimations . . . . .	167
<b>6</b>	<b>RESULTATS EXPERIMENTAUX</b>	<b>175</b>
6.1	Suivi d'obstacles . . . . .	175
6.1.1	Suivi d'obstacles par Lidar . . . . .	175

---

6.1.1.1	Résultats . . . . .	180
6.1.2	Suivi d'obstacles par Radar . . . . .	186
6.1.2.1	Résultats . . . . .	188
6.1.3	Conclusion . . . . .	192
6.2	Fusion de pistages . . . . .	193
6.2.1	Calibrage et datation . . . . .	193
6.2.2	Résultats . . . . .	196
6.2.2.1	Radar+IR . . . . .	196
6.2.2.2	Radar+Lidar . . . . .	198
6.2.3	Conclusion . . . . .	209
6.3	Vérité terrain . . . . .	210
6.3.1	Système de mesures . . . . .	210
6.3.2	Résultats et comparaison des méthodes de fusion . . . . .	211
<b>Conclusion</b>		<b>215</b>

# Liste des figures

1.1	L'écholocalisation de la chauve souris . . . . .	7
1.2	Mars Rover . . . . .	9
1.3	Les phases d'évolution d'un conducteur . . . . .	10
1.4	Exemple de situation en virage . . . . .	11
1.5	La détection des lignes blanches . . . . .	12
1.6	Détection des lignes blanches et localisation du véhicule sur sa voie . . . . .	12
1.7	Prolab 1 . . . . .	13
1.8	Le véhicule NAVLAB . . . . .	14
1.9	Le véhicule VELAC . . . . .	15
1.10	Synoptique de l'architecture VELAC . . . . .	16
1.11	Le véhicule NAVLAB 11 . . . . .	17
1.12	Le véhicule LOLA du LIVIC . . . . .	17
1.13	Visualisation du système de surveillance de LOLA . . . . .	18
1.14	Les projecteurs à xénon bidirectionnels . . . . .	19
1.15	Le système AFIL . . . . .	19
1.16	Toyota Pre-Collision System (PCS) . . . . .	20
1.17	Architecture générale du projet PAROTO . . . . .	22
1.18	Interface visuelle installée dans le véhicule PAROTO . . . . .	23

---

1.19	Architecture matérielle du véhicule PAROTO . . . . .	24
1.20	Exemple d'utilisation du D-BITE pour la localisation des obstacles sur la chaussée . . . . .	26
1.21	Exemple d'interface D-BITE pour la détection d'obstacles . . . . .	26
1.22	Une carte détaillée d'un boulevard . . . . .	28
1.23	Une carte détaillée d'un boulevard . . . . .	29
1.24	Estimation d'état . . . . .	31
2.1	Répartition des causes d'accident . . . . .	34
2.2	Types d'accidents . . . . .	34
2.3	Le télémètre laser LMSZ210-60 . . . . .	38
2.4	Principe de mesure de distance . . . . .	38
2.5	Principe du balayage du faisceau laser avec un miroir rotatif . . . . .	40
2.6	Le repère absolu lié au capteur . . . . .	42
2.7	Image 3D dense : un bureau . . . . .	44
2.8	Image d'intensité dense : un bureau . . . . .	44
2.9	Une vue 3d du bureau au format vrml . . . . .	44
2.10	visualisation d'un voiture à 30m . . . . .	45
2.11	visualisation d'un camion à 50m . . . . .	46
2.12	visualisation d'une moto à 10m . . . . .	46
2.13	visualisation d'un piéton à 11m . . . . .	47
2.14	visualisation d'un obstacle à 40m dans le brouillard . . . . .	47
2.15	Structure du radar PAROTO à une antenne . . . . .	51
2.16	Diagramme d'émission et de réception . . . . .	52
2.17	Diagramme d'antenne Radar constructeur . . . . .	53
2.18	Structure du radar PAROTO . . . . .	55

---

2.19	Caméra thermique PAROTO . . . . .	56
2.20	Aspects thermiques des usagers de la route . . . . .	57
2.21	La définition d'un obstacle . . . . .	57
2.22	Complémentarités et redondances . . . . .	61
2.23	Résultats de segmentation . . . . .	64
2.24	Reconnaissance des obstacles de type voiture . . . . .	66
2.25	Des fausses détections . . . . .	67
2.26	Représentation d'une normale à un obstacle . . . . .	68
2.27	Résultats après ajout de contraintes sur les normales . . . . .	69
2.28	Extraction de la distance radiale . . . . .	74
2.29	Extraction de la vitesse radiale . . . . .	74
2.30	Schéma général du module IR . . . . .	76
2.31	Détection de véhicules par IR : rectangles noirs . . . . .	76
3.1	Le scénario étudié . . . . .	90
3.2	Covariances sur les paramètres pour les différents modèles . . . . .	90
3.3	RMSE sur la distance et vitesse radiale . . . . .	91
3.4	Intéraction conducteur-véhicule . . . . .	93
3.5	Intéraction véhicule-conducteur . . . . .	93
3.6	Intéraction environnement-conducteur . . . . .	94
3.7	Systèmes de coordonnées pour l'étude de la dynamique du véhicule . . . . .	95
3.8	Modèle simple de véhicule . . . . .	95
3.9	Géométrie de direction d'Ackermann . . . . .	98
3.10	Modèle simple de véhicule (latéral) . . . . .	99
3.11	Modèles de route . . . . .	101



3.12	Bornes de Cramer Rao pour $x$ et $\dot{x}$ . . . . .	105
3.13	Bornes de Cramer Rao pour $y$ et $\dot{y}$ . . . . .	106
3.14	Représentation des trajectoires estimées selon l'initialisation de $x_0$ . . . . .	107
3.15	Représentation des trajectoires estimées selon l'initialisation de $y_0$ . . . . .	108
3.16	Représentation des trajectoires estimées selon l'initialisation de $\dot{x}_0$ . . . . .	108
3.17	Représentation des trajectoires selon l'initialisation de $\dot{y}_0$ . . . . .	109
4.1	Structure haut niveau d'un système de surveillance . . . . .	111
4.2	Un module de pistage . . . . .	112
4.3	La densité de probabilité de la mesure : distribution beta . . . . .	128
4.4	Borne De Cramer Rao de la distance radiale selon la distribution du bruit . . . . .	130
4.5	Borne De Cramer Rao de la vitesse radiale . . . . .	131
4.6	Distribution gaussienne et beta . . . . .	132
4.7	PCRB de $x$ et $v_x$ en fonction de $\sigma_\omega$ ( $rad/s$ ) . . . . .	135
4.8	PCRB de $y$ et $v_y$ en fonction de $\sigma_\omega$ ( $rad/s$ ) . . . . .	135
4.9	PCRB de $x$ et $v_x$ en fonction du rayon de courbure . . . . .	136
4.10	PCRB de $y$ et $v_y$ en fonction du rayon de courbure . . . . .	136
4.11	Une fenêtre ellipsoïdale . . . . .	139
4.12	Cas 1 : association PPV . . . . .	140
4.13	Cas 2 : association PPV . . . . .	141
4.14	Cas 3 : association PPV . . . . .	141
4.15	Description de la trajectoire et des observations bruitées . . . . .	145
4.16	Erreur sur $x$ et $\dot{x}$ pour les deux modèles . . . . .	146
4.17	Erreur sur $y$ et $\dot{y}$ pour les deux modèles . . . . .	146
4.18	Erreur sur $x$ et $\dot{x}$ pour les deux modèles . . . . .	147

---

4.19	Erreur sur $y$ et $\dot{y}$ pour les deux modèles . . . . .	147
4.20	Scénario pour la distance radiale . . . . .	148
4.21	Erreur sur $r$ : covariance kalman et rmse . . . . .	149
4.22	Estimation de la trajectoire par filtre de kalman étendu . . . . .	150
4.23	Estimation de la trajectoire par filtrage particulaire . . . . .	151
5.1	schéma du module de fusion . . . . .	155
5.2	Les architectures de fusion de pistages . . . . .	159
5.3	Filtrage de Kalman bimode . . . . .	161
5.4	Architecture de fusion / Filtrage particulaire . . . . .	164
5.5	La trajectoire réelle de la cible . . . . .	167
5.6	Les mesures laser bruitées . . . . .	168
5.7	Les mesures radar . . . . .	168
5.8	La trajectoire estimée par le traitement des mesures lidar . . . . .	169
5.9	Les estimations sur $r$ et $\dot{r}$ à partir du traitement des mesures radar . . . . .	170
5.10	Erreur d'estimation sur $x$ et $\dot{x}$ . . . . .	170
5.11	Erreur d'estimation sur $y$ et $\dot{y}$ . . . . .	171
5.12	Les trajectoires estimées selon la méthode de fusion envisagée . . . . .	171
5.13	Erreur d'estimation sur $x$ et $\dot{x}$ : filtrage particulaire (PF) + EKF . . . . .	172
5.14	Erreur d'estimation sur $y$ et $\dot{y}$ : filtrage particulaire (PF) + EKF . . . . .	172
6.1	Résultats du pistage en $x$ dans un cas mono cible . . . . .	180
6.2	Résultats du pistage en $y$ dans un cas mono cible . . . . .	181
6.3	Résultats du pistage pour $V_r$ dans un cas mono cible . . . . .	181
6.4	Instants a,b et c de la séquence . . . . .	182
6.5	Instants d et e de la séquence . . . . .	182

6.6	Résultats pistage pour $x$ dans un cas multicibles	183
6.7	Résultats pistage pour $y$ dans un cas multicibles cible	183
6.8	Résultats pistage pour $V_r$ dans un cas multicibles	184
6.9	Instants a,b,c,d,e,f,g,h,i et j de la séquence	185
6.10	moto	189
6.11	piéton	190
6.12	deux obstacles	191
6.13	obstacle dans le brouillard	192
6.14	repères capteurs radar et laser	194
6.15	repères capteurs radar et infrarouge	194
6.16	zone de couverture des capteurs	195
6.17	champ radar et ir	195
6.18	Fusion de données dans une situation simple (IR en rouge, Radar en vert, piste bimode en bleu)	196
6.19	Dépassement d'un véhicule, étape 1	197
6.20	Dépassement d'un véhicule, étape 2	197
6.21	Détection Radar non confirmée par l'Infrarouge	198
6.22	Comparaison Kalman / Particule pour R	199
6.23	Comparaison Kalman / Particule pour $x$	200
6.24	Résultat fusion pour distance radiale relative (1)	201
6.25	Résultat fusion pour vitesse radiale relative (1)	201
6.26	Résultat fusion pour cap relatif (1)	202
6.27	Visualisation de la piste radar à 170m	202
6.28	Résultat fusion pour distance radiale relative (2)	203
6.29	Résultat fusion pour vitesse radiale relative (2)	203

---

6.30	Résultat fusion pour cap relatif (2) . . . . .	204
6.31	Représentation des résultats (initialisation d'une piste bimode) . . . . .	206
6.32	Représentation des résultats (dépassement d'un véhicule) . . . . .	207
6.33	Représentation des résultats (insertion d'un véhicule) . . . . .	208
6.34	Représentation des résultats (un obstacle à 90m sur autoroute durant la nuit) . . . . .	209
6.35	Les capteurs mis en jeu . . . . .	211
6.36	Erreur de position sur $r$ . . . . .	212
6.37	Erreur de position sur $r$ . . . . .	213
6.38	Estimation de $r$ (particules) et position GPS . . . . .	214



# Liste des tableaux

2.1	Caractéristiques de balayage des lignes . . . . .	41
2.2	Caractéristiques de balayage des images . . . . .	41
2.3	Caractéristiques du laser pour la mesure de distance . . . . .	41
2.4	Caractéristiques temporelles du laser . . . . .	43
2.5	Bandes de fréquences allouées aux radars automobiles longue portée . . . . .	48
6.1	Choix des conditions initiales . . . . .	178
6.2	Choix des conditions initiales pour le système radar . . . . .	188
6.3	Temps de calcul . . . . .	212



# Introduction

En 1896, dans le quartier de Crystal Palace à Londres, un employé d'une entreprise Anglo-Française de moteurs de voitures, qui effectuait des démonstrations gratuites d'un véhicule pour un public curieux, provoqua le premier accident de la route mortel<sup>1</sup>. Il renversa une femme de 44 ans, Bridget Driscoll, qui marchait tranquillement, accompagnée de sa fille. Arthur Edsell, riche de trois semaines d'expérience de conduite, déclara par ailleurs qu'il discutait avec une jeune femme à l'arrière du véhicule. C'était le premier décès dû à un accident de la circulation. Ce jour là, le responsable de l'enquête judiciaire déclara "This must never happen again". Pourtant, plus d'un siècle plus tard, l'O.M.S. (Organisation Mondiale de la Santé) consacre pour la première fois la journée mondiale de la Santé 2004 à la sécurité routière (Paris). Effectivement, depuis 1974, une résolution de l'assemblée mondiale de la santé déclare que les accidents de la route constituent un problème de santé publique. En 2002, les accidents de la circulation se classent au neuvième rang des principales causes de mortalité dans le monde, avec 1 183 492 morts (plus de morts par jour que le 11 septembre) et Ian Roberts, Professeur en Epidémiologie et Santé Publique, déclare : "D'ici 2020, les accidents de la route auront évolués du neuvième au troisième rang sur l'échelle des principales causes de mortalité dans le monde et à la seconde place dans les pays en voie de développement". C'est dans ce contexte, que le gouvernement français affiche la sécurité routière comme un problème prioritaire depuis de nombreuses années. Même si 90 à 95% de tous les accidents sont en partie dus à une erreur humaine, il ne faut pas croire que les nouvelles améliorations des véhicules n'ont pas de sens. Il faut plutôt considérer que ces nouveaux concepts technologiques ne s'introduiront à grande échelle que si ils font partie d'un système triangulaire de sécurité routière : conducteur, infrastructure, véhicule.

---

<sup>1</sup><http://www.roadpeace.org/articles/WorldFirstDeath.html>



En 1972, pour améliorer la sécurité des usagers et réduire la consommation d'énergie, le port de la ceinture à l'avant devient obligatoire et les limitations de vitesse font leur apparition. Plus récemment, l'évolution des technologies laisse apparaître des systèmes, qualifiés parfois d'intelligents, de sécurité active, dont le but est d'éviter les accidents. On pourra citer par exemple le système d'anti-blocage des roues ABS<sup>2</sup>, le système électronique de stabilité en virage ESP<sup>3</sup>, le régulateur de vitesse à contrôle de distance ACC<sup>4</sup>, l'aide au stationnement, le système récent d'Alerte de Franchissement Involontaire de Ligne baptisé AFIL. A l'opposé, limiter les conséquences d'un accident sera le chantier de la sécurité passive (ceinture, airbag, appuis têtes actifs, ...). La sécurité active est donc vue comme la sécurité primaire sur laquelle de nombreux concepts technologiques seront développés. Comme dit précédemment, le conducteur est en général à l'origine de l'accident, les systèmes intelligents seront donc destinés à assister le conducteur dans sa tâche complexe de conduite et à l'aider à percevoir l'environnement. La fonction de conduite nécessite une observation constante de l'environnement de la part du conducteur, une évaluation permanente de la situation sur la route, et en conséquence des prises de décision (accélérer, freiner, dépasser, ralentir, ...). Des études ont montré qu'un conducteur doit prendre en moyenne 12 décisions par kilomètre. Ceci révèle le caractère ardu et délicat de la tâche de conduite, qui pourra être rendue encore plus difficile par certaines circonstances telles que la densité du trafic, les conditions météorologiques, ou encore l'expérience du chauffeur ou sa condition physique. Il est donc indispensable d'aider le conducteur à percevoir et à rassembler l'information. Bien entendu, le conducteur ne sera en aucun cas réduit à un rôle de passager et pourra à tout moment reprendre le contrôle de son véhicule. Un bon éclairage de l'environnement, du point de vue des capteurs, est donc impératif surtout par mauvais temps, obscurité, brouillard, ... L'aspect de l'infrastructure routière, en particulier à l'avant du véhicule, devra faire l'objet d'une caractérisation précise pour l'évitement des collisions. Le terme collision sera limité, dans notre application, aux différents accidents avec les usagers de la route : voitures, camions, motos, piétons. Il devient donc primordial pour un système de sécurité actif, dont la brique principale est l'anticollision de détecter les différents obstacles potentiels et d'en extraire des caractéristiques essentielles pour la sécurité du conducteur

---

<sup>2</sup>Antilock Braking System

<sup>3</sup>Electronic Stability Program

<sup>4</sup>Adaptive Cruise Control

## ***Introduction***

---

quelles que soient les circonstances.

Dans ce cadre, le groupe GRAVIR, Groupe de Recherche en Automatique et en Vision pour la Robotique, du LASMEA<sup>5</sup> s'attache depuis une quinzaine d'années à la conception de machines dotées de capacités d'autonomie importantes (machines "intelligentes") grâce à des systèmes de perception mettant en oeuvre des capteurs divers tels que : caméras CCD vidéo, radar, lidar, GPS, ... Ses recherches sur les véhicules intelligents débutent en 1988 avec le projet européen PROMETHEUS<sup>6</sup> (1988-1995) : développement des véhicules expérimentaux Prolab1 et Prolab2. Récemment, les deux projets considérant la perception à bord des véhicules routiers intelligents sont dans cette unité mixte de recherche du CNRS, le projet ARCOS<sup>7</sup> et le projet PAROTO<sup>8</sup> du PREDIT<sup>9</sup>. Ses compétences (robotique, vision artificielle, fusion de données multisensorielles) dans le domaine se regroupent autour des trois piliers de la sécurité, du point de vue perceptif : la détection d'obstacles, la reconnaissance de la route et de la signalisation et la localisation du véhicule sur la chaussée.

Les travaux décrits dans ce manuscrit s'intègrent dans la brique de détection d'obstacles et visent à développer un système d'anticollision à l'avant du véhicule ainsi qu'un système de gestion des interdistances (distances entre véhicules). Il ne faut pas croire ici que la détection d'obstacles se limite à l'extraction de signaux remarquables parmi un ensemble de signaux indépendants. Il sera aussi indispensable de fournir au système d'alerte des estimations sur la trajectoire et/ou l'état des obstacles. En outre, il est reconnu que l'on peut avoir des incertitudes associées aux mesures des capteurs en plus de leur inexactitude généralement modélisée par des bruits de mesure. Ces incertitudes concordent avec l'origine des mesures : une mesure pourra éventuellement ne pas provenir de la cible (fausse détection, clutter). De plus, il faudra gérer (initialisation, maintien, destruction) les différents obstacles potentiels éclairés par les différents capteurs. On parlera de pistage monocible et multicibles. Au premier abord, le pistage peut être ressenti comme un cas d'estimation. Cependant, non seulement il utilise les outils de l'estimation mais il nécessite l'utilisation de la théorie statistique de décision quand des problèmes pratiques (association de données-Est ce que c'est ma mesure ?)

---

<sup>5</sup>Laboratoire des Sciences et Matériaux pour l'Electronique et d'Automatique

<sup>6</sup>Programme for an European Traffic with Highest Efficiency and Unpressed Safety

<sup>7</sup>Action de Recherche pour une CONduite Sécurisée

<sup>8</sup>Projet Anticollision Radar et Optronique pour l'auTOMobile

<sup>9</sup>Programme de REcherche et D'Innovation dans les Transports terrestres

sont considérées. De plus, notre système devra fonctionner quelles que soient les circonstances météorologiques (nuit, soleil, pluie, brouillard) de manière efficace. Sous ces conditions, l'utilisation d'un seul capteur sera parfois inefficace. En effet, un seul capteur n'est capable de fournir qu'une information partielle de l'environnement et par conséquent sa capacité à l'interpréter est limitée. C'est pourquoi, ces dernières années, l'intérêt pour les systèmes multisensoriels ne cesse d'augmenter. Pour obtenir un bénéfice de ces différents capteurs, il est nécessaire que l'information fournie par ceux-ci soit interprétée et combinée afin d'avoir une description de l'environnement précise et cohérente. L'étude des complémentarités et redondances des capteurs sera la base pour le choix des capteurs formant le système multisensoriel. Néanmoins, l'extraction d'information reste un pas crucial avant la fusion d'information qui est vu ici comme la combinaison de différentes sources. En sus, il est naturel que la fusion prenne en compte les incertitudes existantes sur les différentes sources. La quantification de la précision de l'information à fusionner est donc primordiale. L'information fusionnée devra représenter une entité plus en détails et avec moins d'incertitudes que ce qui est disponible à n'importe laquelle des différentes sources. Ce système s'appuiera sur des traitements numériques tels que le traitement du signal, la reconnaissance des formes et pour sa majeure partie de l'estimation.

Le premier chapitre de ce manuscrit débute par une description globale de méthodes de perception de l'environnement routier pour fixer le contexte de notre étude. Ensuite, un tour d'horizon des différents véhicules intelligents existants, qu'ils soient en phase de développement ou commercialisés, et des différents projets où nos travaux s'intègrent, est proposé. La deuxième partie de ce chapitre propose une introduction générale sur les buts recherchés accompagnée d'une description globale des méthodes d'estimation et de fusion.

Dans le deuxième chapitre, l'accent sera mis sur l'extraction des mesures liées aux capteurs. Une description des méthodes développées pour un lidar<sup>10</sup>, un radar<sup>11</sup>, et une caméra infrarouge<sup>12</sup> sera proposée. Pour le lidar, la méthode de détection utilise la capacité de ce capteur à délivrer, avec précision, une représentation tridimensionnelle de l'environnement éclairé par le capteur. Du côté du radar, on insistera plus sur le module de traitement du signal qui délivre en sortie un ensemble d'échos

---

<sup>10</sup>Riegl LMSZ210-60

<sup>11</sup>LASMEA-Radar Doppler à priorité Doppler

<sup>12</sup>SAGEM

## ***Introduction***

---

affectés d'une mesure de distance et d'une mesure de vitesse relative. Pour la caméra infrarouge, on évoquera la méthode développée par la SAGEM. Après le traitement des données capteurs, des mesures, qui pourront être qualifiées d'observations, sont disponibles. Ces mesures seront les entrées des différents modules d'estimation dont le but sera de mettre en phase les propriétés physiques de l'objet d'intérêt (cible, obstacle) et des capteurs avec les paramètres d'un modèle mathématique, à savoir la caractérisation statistique d'un processus aléatoire décrivant les incertitudes du problème.

En prélude à l'estimation d'état, l'estimation de paramètres est abordée au chapitre trois afin de caractériser les trajectoires des véhicules considérés et afin de montrer le concept de limite d'information extractible d'un système.

Le pistage qui regroupe l'estimation d'état, le filtrage et l'utilisation de la théorie statistique de décision est l'objet du chapitre quatre. Ce pistage est formé de plusieurs briques dont l'une des principales est l'estimation des caractéristiques des obstacles à suivre. Ces estimations s'appuient sur la théorie bayésienne. Elles sont basées sur les méthodes de filtrage de Kalman et filtrage particulière. D'autre part, il est nécessaire de gérer judicieusement les pistes pour éviter la multiplication de fausses pistes pouvant porter préjudice au système d'assistance. On évoquera donc l'association de données, l'initialisation et la destruction de pistes.

Le cinquième chapitre présentera l'utilisation des mesures et des estimations délivrées par les systèmes de détection et de pistage. Ce système de plus haut niveau aura donc comme objectif la gestion robuste de toutes les pistes et mesures provenant de capteurs indépendants. Il devra délivrer des informations qu'un système monocapteur ne peut fournir dans toutes les circonstances. On parlera de combinaison de pistages. Cette combinaison débutera naturellement par l'association de deux pistes que l'on qualifiera de pistes capteurs. L'association de deux pistes capteurs réalisée, la combinaison des mesures sera produite par un module de fusion dont les entrées seront les pistes capteurs accompagnées des mesures et dont les sorties seront les caractéristiques essentielles des obstacles potentiels, à savoir les positions et vitesses relatives au véhicule équipé. Le fruit de cette combinaison sera donc un ensemble d'estimations du comportement des obstacles, que l'on pourra intégrer à un système haut-niveau de caractérisation de l'environnement prenant en compte la formalisation triangulaire "infrastructure-conducteur-véhicule".

Finalement, de nombreux résultats expérimentaux utilisant nos méthodes seront détaillés dans le chapitre six.




# Chapitre 1

## INTRODUCTION GENERALE

### 1.1 La perception à bord des véhicules routiers intelligents

#### 1.1.1 Introduction



*Figure 1.1* — L'écholocation de la chauve souris

Les petites chauves-souris ou microchiroptères se dirigent en vol et, pour la plupart des espèces insectivores ciblent également leur proie par écholocation (voir figure 1.1), c'est-à-dire par émission pulsée de sons de haute fréquence (entre 20 et 120 KHz) qui sont réfléchis sous forme d'échos (perçues par les oreilles de la chauve-souris) par les surfaces environnantes. Ces échos renseignent l'animal sur la position, la distance relative et même la nature des objets de son environnement. Ceci permet aux

microchiroptères de voler dans l'obscurité totale. Les grandes chauves-souris ou mégachiroptères se servent de la vue plutôt que de l'ouïe pour s'orienter. Une seule espèce a évolué vers un mécanisme d'écholocalisation qui met en jeu l'émission de "clics" audibles et ne sert que quand les chauves-souris volent dans l'obscurité. Aucune chauve-souris n'est aveugle, et même les microchiroptères qui utilisent l'écholocalisation peuvent se servir de repères de grandes dimensions pour se diriger en vol. A l'opposé l'être humain utilisera de façon prioritaire sa vue pour observer, analyser, reconnaître l'environnement. La vue est donc le moyen de perception primaire chez l'homme alors que chez la chauve-souris c'est l'ouïe. Dans l'obscurité, l'être humain, à l'opposé des microchiroptères, ne pourra donc pas percevoir d'une manière précise l'environnement dans lequel il évolue. Il s'est donc attaché à développer des systèmes de vision nocturne.

D'une manière plus globale, la recherche en robotique développe, depuis de nombreuses années, des moyens de percevoir l'environnement dans des circonstances où la capacité de l'être humain à maîtriser son évolution est limitée, où sa présence est inadaptée. On pourra citer par exemple le développement de robots pour le démantèlement de centrale nucléaire ou d'exploration planétaire. La multiplication des capteurs de perception (caméra, Lidar, Radar, caméra Infrarouge, capteurs inertiels, ...) offre à la robotique une capacité d'évolution de plus en plus importante. Par exemple, la NASA<sup>1</sup> a développé un robot capable d'évoluer de façon quasi-autonome sur la planète Mars pendant au moins trois mois (figure 1.2). Ce robot est équipé d'une multitude de capteurs, pour remplacer le champ d'action d'un géologue afin de rechercher des indications quant à l'évolution de la planète Mars. Il est équipé d'une caméra panoramique placée au niveau des yeux d'un homme, d'un mini spectromètre à émission thermique, d'une caméra infrarouge pour aider les scientifiques à identifier les pierres les plus intéressantes. Les six roues, sur lesquelles se greffe des panneaux solaires pour fournir l'alimentation nécessaire, permettent au robot de se diriger vers la roche sélectionnée. Ensuite, il détend un bras mécanique équipé d'outils. Un imageur microscopique donne une vue précise de la texture de la roche et deux spectromètres identifient la composition de la roche. Enfin, un dernier outil, remplaçant le marteau du géologue, gratte la roche pour en découvrir la surface interne.

---

<sup>1</sup>National Aeronautics and Space Administration




Figure 1.2 — Mars Rover

Dans un contexte plus terrestre, la perception à bord des véhicules routiers intelligents relève du domaine de la sécurité routière. Par analogie avec l'exploration de la planète Mars par un robot, un véhicule intelligent doit être capable de fournir des informations sécuritaires quant à son environnement, la plupart du temps inconnu. Le schéma de la figure 1.3 rappelle les différentes phases dans lesquelles peut se trouver un conducteur. Il propose aussi les possibilités qui existent au cours de ces phases pour alléger la tâche du conducteur ou protéger de manière optimale les occupants et les autres usagers de la route. Les trois premières phases relèvent du domaine de la sécurité active, c'est-à-dire qu'aucun accident ne s'est encore produit et que les systèmes à bord du véhicule mettent tout en oeuvre pour éviter un crash. La sécurité passive est identifiée par les autres phases. Notre contribution se place au niveau de la perception de l'environnement routier et en particulier au niveau de la détection d'obstacles. La détection d'obstacles est une des trois missions de la perception de l'environnement routier. On propose, dans une première partie, une description générale des missions de la perception de l'environnement routier. On insistera sur les fonctions utiles pour la détection d'obstacles, en particulier la reconnaissance de la route et la localisation du véhicule par rapport à celle-ci. Ensuite, on proposera un bref tour d'horizon des plate formes expérimentales et des véhicules intelligents commercialisés. Les travaux de ce manuscrit concourent à différents projets du LASMEA qui seront décrits dans une troisième partie.






Figure 1.3 — Les phases d'évolution d'un conducteur

### 1.1.2 Missions pour la perception de l'environnement routier

La perception de l'environnement routier peut se définir autour de trois fonctions essentielles :

- La détection d'obstacles ;
- la reconnaissance et la reconstruction de la route et de la signalisation ;
- la localisation du véhicule sur la chaussée.

Ces fonctions s'appuient sur l'utilisation d'un mécanisme de perception à trois niveaux hiérarchiques. Par exemple, pour la reconnaissance des signalisations, le premier niveau ("Reconnaître") nécessite de connaître l'existence des routes, des carrefours et de la circulation routière. Le deuxième niveau ("décoder") utilise la connaissance du code de la route et le troisième niveau ("utiliser") exploite cette information pour respecter la signalisation. Cette reconnaissance attirera l'attention du conducteur qui souvent s'y perd dans la multitude de panneaux.

D'un côté plus sécuritaire, il est effectivement judicieux de localiser le véhicule dans sa voie de circulation (position, orientation) et de déterminer la géométrie tridimensionnelle de la chaussée. Cette fonction nécessite donc la connaissance de la position des bords de la route. Cette détection pourra alimenter un système de détection d'obstacles pour identifier les véhicules présents dans cette voie [66]. En effet, particulièrement en situation de virage l'analyse des bords de voie constitue une aide précieuse en vue de la localisation des obstacles sur la chaussée (voir figure 1.4). De nombreuses





Figure 1.4 — Exemple de situation en virage

méthodes de reconnaissance et de reconstruction de la chaussée par vision sont présentes dans la littérature. Une bonne description de celles ci est disponible dans [5]. De plus, l’auteur propose une méthode de reconnaissance des bords d’une route fonctionnant à la fois dans le contexte des routes marquées mais également dans celui des routes non marquées (voir figure 1.5). Cette méthode est basée sur l’utilisation d’un modèle statistique, d’ordre élevée, représentant précisément la position des bords de la route dans l’image. Ce modèle permet en outre de gérer efficacement la cohérence entre les deux bords afin de limiter la sensibilité de l’approche aux fausses détections ou aux occultations. Une étape de localisation est ensuite réalisée pour envisager un guidage (voir figure 1.6). Une



*Figure 1.5* — La détection des lignes blanches



*Figure 1.6* — Détection des lignes blanches et localisation du véhicule sur sa voie

nouvelle approche de localisation absolue est développée dans [65]. Ce système est capable de fournir la position globale et l’orientation du véhicule sur la route en utilisant une carte numérique. Un vecteur d’état  $(x, y, z, \alpha, \beta, \gamma)^t$  est utilisé pour représenter l’attitude du véhicule.  $x, y, z$  sont les coordonnées du véhicule et  $\alpha, \beta, \gamma$  sont les angles définissant l’orientation relative du véhicule dans le repère lié à la carte. Il combine l’information fournie par de nombreux capteurs proprioceptifs et extéroceptifs : un odomètre, un capteur d’angle au volant, un GPS bas-coût couplé à une carte qui donne une précision

d'environ 30 m, et un système de reconnaissance de la route basé sur l'utilisation de la vision qui donne l'orientation et la position latérale du véhicule sur la route. Les estimations et mises à jour du vecteur d'état sont réalisées à partir de méthodes particulières.

La perception de l'environnement routier s'appuie inévitablement sur l'utilisation de plate formes expérimentales. Ces plate formes sont nombreuses et de qualité. Nous nous intéressons ici à quelques unes d'entre elles. Le point sera fait sur les véhicules commercialisés.

### 1.1.3 Les véhicules intelligents : état de l'art non exhaustif

Pour valider les différents systèmes utilisés afin d'assister le conducteur, des plateformes expérimentales sont indispensables. La plupart des concepts de véhicules intelligents ont été imaginés dans les années 80. En Europe, le premier projet stimulateur est certainement le projet EUREKA-PROMETHEUS (1988-1995). En France, le groupe Pro-Art avait pour but le développement des véhicules expérimentaux Prolab1 et Prolab2. Prolab1 (voir figure 1.7) était équipé d'un capteur multi-sensoriel basé sur le couplage d'une caméra vidéo et d'un télémètre laser pour la détection d'obstacles, d'une caméra vidéo pour la reconnaissance de la route et de capteurs proprioceptifs afin de connaître son état. D'autres projets européens, plus récents, seront décrits dans la partie suivante. Aux États-



Figure 1.7 — Prolab 1

Unis dans le cadre des travaux de l'Université de Carnegie-Mellon, Thorpe décrit, en 1988, dans [97], un système de vision et de navigation. Il utilise un van (voir figure 1.8) équipé d'une caméra couleur et d'un télémètre laser. Aujourd'hui ce laboratoire, CMU NAVLAB, expérimente ses méthodes de perception sur un onzième véhicule : NAVLAB 11 dont une description est donnée ci après. On s'intéressera également à d'autres véhicules et en particulier à VELAC (Véhicule Expérimentale du



*Figure 1.8* — Le véhicule NAVLAB

LASMEA pour l'Aide à la Conduite).

### 1.1.3.1 Quelques plateformes expérimentales

**VELAC** Riche de son expérience dans le projet européen PROMETHEUS, le LASMEA s'est équipé en 1998 d'un véhicule expérimental nommé VELAC (Véhicule Expérimental du LASMEA pour l'Aide à la Conduite). Ce véhicule est une Citroën Evasion (voir figure 1.9). Il est équipé de nombreux capteurs proprioceptifs et extéroceptifs. Le schéma de la figure 1.10 résume l'architecture de la plateforme expérimentale. L'utilisation de ces différents capteurs permet une représentation globale de la scène routière tant du point de vue de la localisation de VELAC lui-même que de la détection d'obstacles. Un système utilise les capteurs proprioceptifs (angle au volant, odomètre, gyromètre) et les capteurs extéroceptifs (Caméra, GPS) pour une localisation précise à l'aide d'une carte numérique connue de l'environnement.



Figure 1.9 — Le véhicule VELAC

De l'autre côté l'utilisation combinée de capteurs extéroceptifs (caméra, Lidar, Radar, IR) permet la détection des différents obstacles potentiels et l'alerte du conducteur. Ce processus de détection sera décrit dans les chapitres suivants. L'alerte du conducteur pourra se faire par l'utilisation d'un bandeau de LED (voir projet PAROTO) et/ou d'un système de vibreur pour la pédale d'accélérateur. L'alerte s'appuie sur les estimations des caractéristiques des obstacles détectés et sur l'utilisation du comportement du véhicule (accélérateur, frein, vitesse, angle au volant, clignotant, embrayage). On pourra pour une représentation précise de l'environnement combiner les résultats de la localisation et de la détection d'obstacles : les obstacles seront aussi localisés sur la carte de l'environnement.

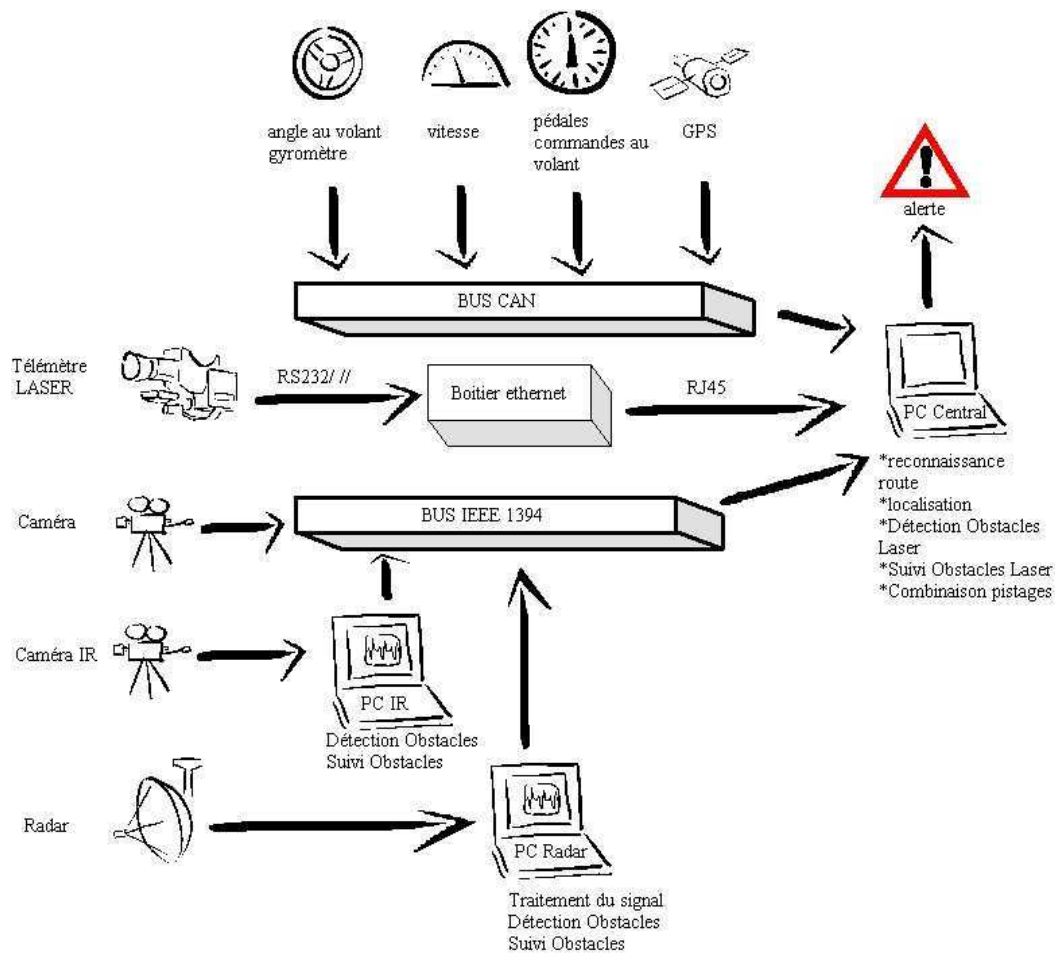


Figure 1.10 — Synoptique de l'architecture VELAC

**NAVLAB 11** Le groupe Navlab de l'Université de Carnegie Mellon University a une longue histoire dans le développement de véhicules intelligents pour l'assistance à la conduite. Les travaux les plus récents se concentrent sur le suivi de route, conduite cross-country, et la détection d'obstacles. Certains chercheurs du groupe focalisent aujourd'hui leur intérêt sur l'environnement proche du véhicule, en observant tout autour de celui-ci pour une conduite sans danger [6]. Le système actuel utilise un capteur vidéo, des capteurs de distance laser, un nouveau capteur de distance laser line-stripe, des logiciels pour traiter les mesures des différents capteurs indépendamment, un système de fusion, et un modèle de prédiction basé sur les probabilités. Le système complet est installé sur Navlab 11 (voir figure 1.11) pour évaluer un environnement urbain : détection et pistage des objets fixes, des objets en mouvement, des piétons, des trottoirs et des routes.





Figure 1.11 — Le véhicule NAVLAB 11

**LIVIC** Le LIVIC <sup>2</sup>, unité mixte LCPC <sup>3</sup> et INRETS <sup>4</sup>, a pour mission d'exercer des activités de recherche, de développement et d'expérimentation visant à faire émerger des systèmes d'aide à la conduite et à faire évoluer l'infrastructure associée. Du point de vue des systèmes d'assistance à la conduite, ce laboratoire utilise plusieurs plateformes expérimentales. Une de ces plateformes, LOLA (voir figure 1.12), est capable de conduire automatiquement. Elle est équipée d'un télémètre laser à



Figure 1.12 — Le véhicule LOLA du LIVIC

<sup>2</sup>Laboratoire sur les Interactions Véhicules-Infrastructures-Conducteurs

<sup>3</sup>Laboratoire Centrale des Ponts et Chaussées

<sup>4</sup>Institut National de REcherche sur les Transports et leur Sécurité



balayage capable de fournir un positionnement centimétrique des objets à une haute fréquence (77 Hz) aussi bien qu'une estimation de leur largeur et de leur longueur, quand le côté de l'objet est visible. De plus, un module de stéréovision basé sur la construction et l'analyse de l'image "v-disparité" [4] fournit une bonne représentation de la scène routière. Enfin, un module de fusion permet d'avoir une représentation robuste de la scène routière dans les zones de chevauchement des champs de vue des deux capteurs. La distance qui sépare les deux voitures est visualisée sur un écran (voir figure 1.13). Pour le contrôle latéral, une caméra centrale visualise la bande de circulation. En cas d'écart, LOLA corrige automatiquement la trajectoire.



Figure 1.13 — Visualisation du système de surveillance de LOLA

### 1.1.3.2 Les véhicules intelligents commercialisés

Une voiture française "grand public" commercialisée proposant des systèmes innovants pour la sécurité active est la Citroën C5 (2004). L'ESP (ou contrôle dynamique de stabilité), de série, est associée à l'antipatinage, l'ABS, l'aide au freinage d'urgence, et intègre une nouvelle répartition de freinage roue par roue et un système de contrôle de stabilité pour corriger "sous" et survirage. Elle possède aussi un nouveau système d'aide à la conduite de nuit : les phares à xénon (proche de la luminosité du jour) bidirectionnels. Ils permettent d'éclairer des piétons et des objets placés sur la route au niveau d'un virage (voir figure 1.14). Elle propose également un limiteur de vitesse, qui permet au conducteur de définir une vitesse maximale quelle que soit la position de son pied sur l'accélérateur. Enfin, la nouvelle C5 est équipée de l'Alerte de Franchissement Involontaire de



Figure 1.14 — Les projecteurs à xénon bidirectionnels

Ligne (AFIL). Ce système d'aide à la conduite prévient le conducteur lorsqu'une dérive par rapport à la ligne blanche est constatée. Le conducteur est averti par des vibreurs placés dans l'assise de son siège lors d'un instant de déconcentration ou d'un assoupissement (voir figure 1.15). Du côté




Figure 1.15 — Le système AFIL

des constructeurs étrangers, de nombreux systèmes d'assistance existent. Le système passif Pre-Safe, qui équipe les Mercedes classe S (2003), est capable de détecter si un accident est imminent. En

utilisant l'ESP et le BAS<sup>5</sup>, Pre-Safe, tend, de manière préventive, les ceintures de sécurité, ferme le toit ouvrant et repositionne les sièges pour mieux protéger les occupants en cas d'impact. Le constructeur Toyota, a rejoint Mercedes sur ce créneau en développant son système de pré-collision, dénommé PCS<sup>6</sup> (figure 1.16). Il utilise un radar à onde millimétrique placé à l'avant du véhicule afin de détecter les objets arrivant à grande vitesse vers le véhicule. Ce système équipe la Toyota Lexus GS (2004). De nombreux autres véhicules sont équipés d'un système ACC. Ce système élargit les fonctions du




Figure 1.16 — Toyota Pre-Collision System (PCS)

régulateur de vitesse conventionnel par une régulation de la distance et de la vitesse grâce à une intervention automatique sur le pilotage du moteur et sur les freins. Il se base sur l'implémentation d'un capteur radar à l'avant du véhicule pour capter la distance des objets qui précèdent. Par exemple, un système ACC équipe certaines BMW depuis l'an 2000. Ce système propose, par l'utilisation d'un capteur radar à fréquence d'émission 76–77 GHz, deux modes de services différents. Un mode de circulation libre dans lequel l'ACC assure automatiquement la régulation sur la vitesse souhaitée. Un mode de poursuite, signalé au conducteur par un voyant de contrôle, qui maintient, par rapport au véhicule qui précède, la distance en secondes préalablement choisie par le conducteur. L'ACC assure automatiquement la régulation de la vitesse en intervenant sur le moteur et sur les freins. Dès que la voie est libérée, le voyant de contrôle s'éteint et la vitesse souhaitée est rétablie.

<sup>5</sup>Brake Assist Sensors

<sup>6</sup>Pre-Collision System

#### 1.1.4 Les différents projets du LASMEA

Les développements décrits dans ce manuscrit concourent aux différents projets décrits ci-dessous.

##### 1.1.4.1 le projet ARCOS

Le projet ARCOS<sup>7</sup> s'inscrit dans le cadre des actions fédératives du PREDIT. Il associe une soixantaine de partenaires, laboratoires publics et entreprises privées, autour des équipementiers automobiles pour un investissement d'environ 85MF sur 3 ans. Il concerne le domaine de la sécurité routière et son objectif à terme est la réduction de 30% des accidents. Ces accidents peuvent résulter d'une erreur humaine mais aussi d'un problème lié à l'environnement (météo, ...), d'un problème lié à l'infrastructure ou au véhicule. Ce projet s'appuie donc sur le système global représenté par l'infrastructure, le véhicule et le conducteur pour la réalisation de quatre fonctions qui constituent le coeur d'ARCOS :

- gérer les interdistances entre les véhicules ;
- prévenir les collisions sur obstacles fixes, arrêtés ou lents ;
- prévenir les sorties de route ;
- alerter les véhicules en amont d'accidents/d'incidents.

ARCOS est organisé selon onze thèmes (perception à l'avant du véhicule / visibilité, adhérence / traitement de l'information, contrôle-commande / communication / accidentologie, simulation / système homme-machine / aspects économiques / expérimentation, intégration, analyse fonctionnelle / poids lourds) qui permettent d'intégrer les nombreuses complémentarités des sciences de l'ingénieur, des sciences humaines, et des sciences sociales. Le but est de proposer des moyens d'interactions avec le conducteur afin de l'assister. Ces moyens sont différenciés par leur degré d'action :

- des moyens d'information (pas d'actions) ;
- des moyens inter-actifs (actions coopératives) ;
- des moyens actifs (actions déléguées).

Il s'agit dès lors de renforcer l'intelligence et l'efficacité du système « véhicule conducteur infrastructure » en améliorant la qualité et la fiabilité des interactions. Les véhicules sont ainsi capables

---

<sup>7</sup><http://www.arcos2004.com/>

d'une plus grande autonomie par rapport au conducteur. Grâce à des capteurs et des moyens de traitement embarqués, ils sont capables de surveiller leur environnement proche. Des moyens de communication leur permettent également de réagir à des incidents plus éloignés au-delà de la portée des capteurs. Faisant la synthèse de l'ensemble de ces informations, les équipements embarqués des véhicules sont capables d'établir l'assistance au contrôle longitudinal et latéral grâce aux fonctions d'information et de contrôle-commande. Au-delà du triangle « véhicule-conducteur-infrastructure », l'originalité d'ARCOS tient à la volonté de faire évoluer la conception des aides à la conduite vers une intégration de l'ensemble des systèmes, y compris du comportement des autres usagers. Une journée de présentation des résultats/démonstrations est prévue le 28 octobre 2004 à Versailles-Satory. Les travaux de ce manuscrit se situent au niveau de la gestion des interdistances entre les véhicules et de la prévention des collisions sur obstacles fixes, arrêtés ou lents.

#### 1.1.4.2 le projet PAROTO

Le projet PAROTO, qui regroupe le LASMEA, l'INRETS, la SAGEM et TEAM, consiste à développer un démonstrateur de système anti-collision pour automobile qui associe des capteurs radar et caméra thermique, fusionne leurs données, fournit une alarme ou alerte au conducteur et se termine par une évaluation comportementale du système. Le but est d'alerter le conducteur et non d'avoir un comportement actif sur le véhicule. L'architecture générale du projet est décrite figure 1.17. Les capteurs fournissent des signaux à un module de traitement dont la sortie propose une infor-

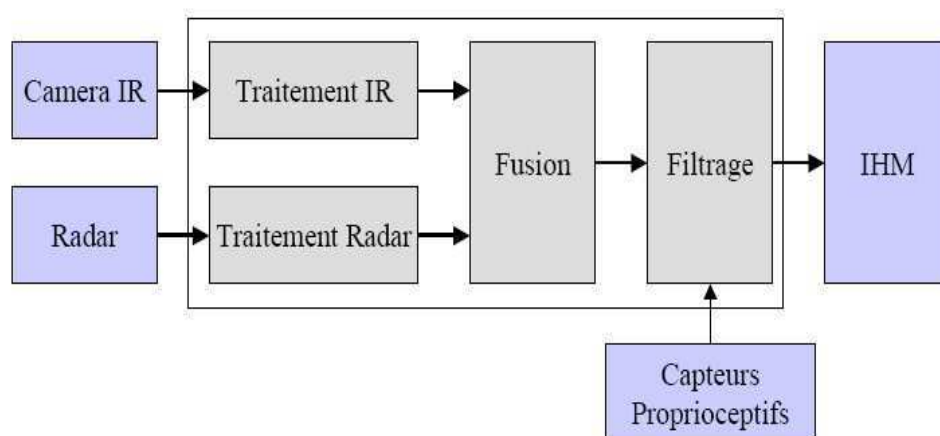


Figure 1.17 — Architecture générale du projet PAROTO

mation haut-niveau (estimations des caractéristiques des obstacles) à un module de fusion. On parlera ici de fusion décentralisée. Cette combinaison d'information permet une caractérisation robuste et précise des obstacles et sera l'objet du chapitre quatre. La caractérisation est analysée par un module de filtrage, utilisant des données proprioceptives (angle au volant, accélérateur, frein, clignotant), qui commande une interface homme-machine (IHM) en cas de besoin. L'IHM (voir figure 1.18), composée d'un bandeau de diodes lumineuses, propose deux modes d'interaction avec le conducteur et une représentation spatiale des obstacles. Le premier mode consiste à orienter le conducteur sur un événement potentiellement dangereux, le deuxième est un mode d'alarme ciblant un danger imminent. Pour la représentation spatiale, le mode d'orientation de l'attention est activé sous la forme d'une série de diodes qui s'allument de façon dynamique (en suivant la trajectoire de l'obstacle et de l'orange au rouge, en fonction du temps à collision) sur le tableau de bord du véhicule. Le mode d'alarme est une combinaison de deux types d'alarme donnés simultanément : une interface visuelle (diodes rouges en face du conducteur) et une interface sonore. La combinaison des informations four-



*Figure 1.18* — Interface visuelle installée dans le véhicule PAROTO

nit au système de filtrage un ensemble de caractéristiques d'obstacles. Ce module de filtrage contient un certain nombre de règles utilisant les données issues de la fusion et les valeurs des capteurs de comportement du conducteur. Il adapte donc le niveau d'information (alarme, mise en attention), son intensité (faible, forte) et le mode de diffusion (visuel, sonore), en fonction du type de danger, de son urgence et de la prise en compte du comportement du conducteur. L'architecture matérielle du véhicule PAROTO, VELAC, est présentée sur la figure 1.19. La liaison caméra Infrarouge-PC IR est une liaison analogique. Les dates affectées aux pistes Infrarouge correspondent aux instants d'acquisitions des images. Les pistes IR alimentent le module de fusion via un réseau local. La liaison Radar-PC Radar est une liaison analogique. Les pistes Radar, affectées des dates d'acquisitions des mesures Radar, alimentent le module de fusion par le bus IEEE 1394. Le bus IEEE 1394 met à dis-

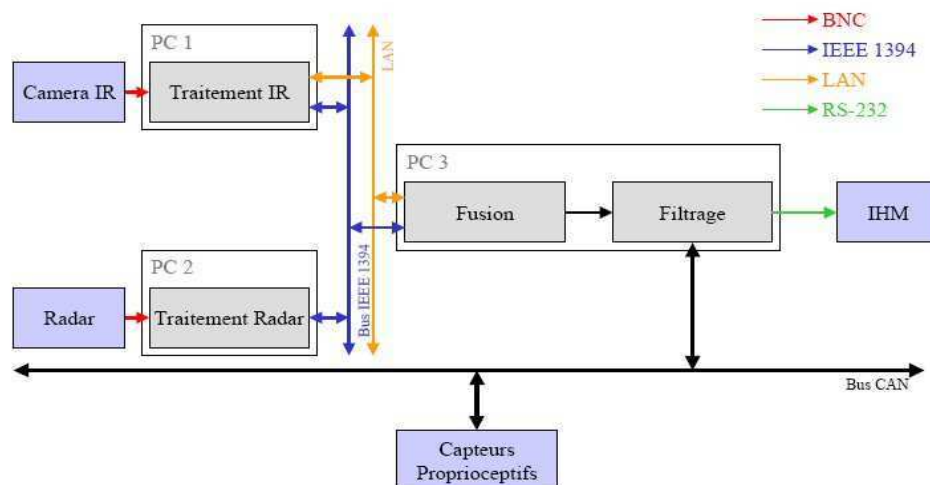


Figure 1.19 — Architecture matérielle du véhicule PAROTO

position des différents matériels connectés une horloge commune, qui nous sert de référence pour la mise en correspondance des pistes capteurs. Notre collaboration dans ce projet se situe au niveau du développement du capteur Radar, de l'analyse de ces données, et de la combinaison des pistages Radar et IR.

### 1.1.4.3 le projet ROADSENSE

L'objectif principal du projet ROADSENSE<sup>8</sup>, qui comprend une dizaine de partenaires, est le développement d'une structure standard pour les interactions homme-véhicule (HVI : Human Vehicle Interactions) et en particulier les interfaces homme-machine (IHM). Ce projet vise à livrer des directives pour les méthodes d'essais d'HVI qui mesurent les effets sur le comportement du conducteur que n'importe qu'elle technologie simple, ou combinaison de technologies, aura. Plus précisément, les objectifs de ROADSENSE sont :

- Objectifs scientifiques :
  - développer des indicateurs comportementaux du conducteur ;
  - développer une structure pour l'intégration des outils existants et des techniques concernant les capacités sensorielles et cognitives du conducteur ;

<sup>8</sup>ROad Awareness for Driving via a Strategy that Evaluates Numerous SystEms

- identifier de nouveaux outils et techniques pour les scénarios critiques, et étudier les technologies proposées par l'industrie ;
- développer une structure dans laquelle les techniques de validation d'HVI peuvent être examinées.
- Objectifs techniques :
  - développer un prototype basé sur la technologie DSP et sur une communication série rapide pour simuler un réseau de véhicule ;
  - développer des outils programmables de simulation de système pour l'évaluation des IHM ;
  - développer une plate forme permettant une approche modulaire et une mise à jour pour les futures technologies.

Ces objectifs sont la base du développement d'une interface D-BITE (Driver Behaviour Interface Test Equipment) pour simuler et valider les nouvelles HVI. Cette interface permet :

- la synchronisation des données ;
- le traitement temps réel ;
- gestion, enchaînement des tâches ;
- le rejeu des données synchronisées ;
- la représentation/visualisation des données ;

Par exemple pour la localisation des obstacles sur la chaussée on pourra utiliser les modules décrits sur la figure 1.20. Cette représentation modulaire pourra être utilisée en temps réel ou pour le rejeu des données. Une représentation d'une interface pour la détection d'obstacles est donnée sur la figure 1.21.



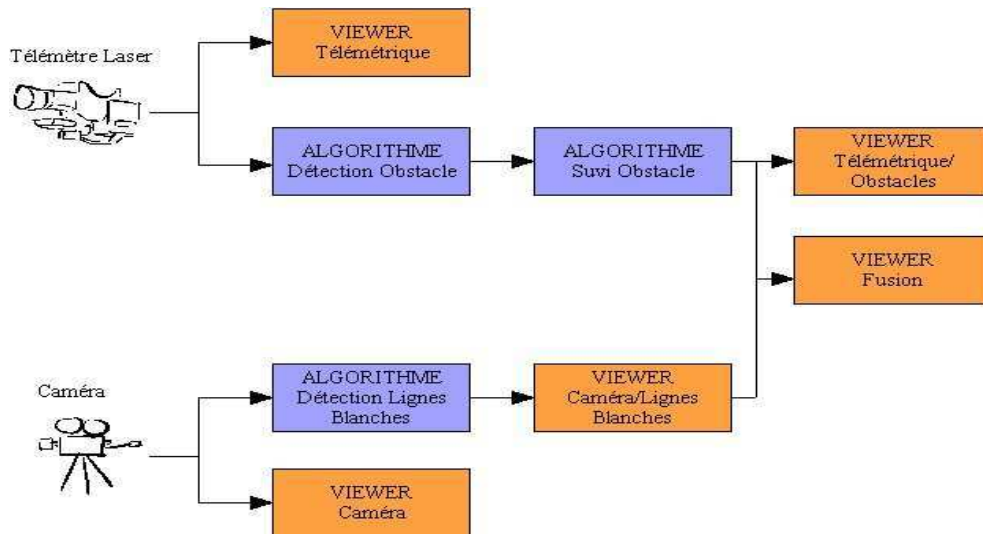


Figure 1.20 — Exemple d'utilisation du D-BITE pour la localisation des obstacles sur la chaussée





Figure 1.21 — Exemple d'interface D-BITE pour la détection d'obstacles

On a présenté une brève description de plusieurs projets dont les objectifs principaux se regroupent autour de la réduction du nombre d'accidents. Tous ces systèmes se basent sur la représentation triangulaire de la sécurité routière (infrastructure-véhicule-conducteur). Plusieurs véhicules expérimentaux et commercialisés ont été présentés. Les plateformes expérimentales sont indispensables pour la validation des méthodes développées. Ces méthodes dépendent bien sûr des capteurs utilisés. Les capteurs peuvent être du type extéroceptifs ou proprioceptifs. On pourra associer le caractère extéroceptif des capteurs à la sécurité active même si des capteurs comme le GPS peuvent être utiles pour la sécurité passive (localisation post-accident pour prévenir les secours par exemple). Dans le chapitre suivant, on s'intéressera aux différents capteurs utiles à la perception de l'environnement, en particulier à la détection d'obstacles. Une description des capteurs utilisés dans nos systèmes de perception sera effectuée.

## 1.2 Buts recherchés

Notre travail s'inscrit dans la bricole de détection d'obstacles. Il est clair que dans un contexte de conduite, il est important de qualifier l'environnement en terme d'obstacles pour éviter les collisions et/ou gérer les interdistances. Par exemple, notre application pourra s'intégrer dans une application pour l'ACC : dans un contexte autoroutier, le conducteur n'aurait plus qu'à s'occuper du volant. Les mouvements longitudinaux du véhicule seraient fixés par l'obstacle le plus dangereux devant le véhicule. De plus, avec l'essor actuel des régulateurs de vitesse, nos travaux seraient facilement intégrables : il suffirait de régler (avec souplesse bien entendu !) la vitesse de l'observateur en fonction de l'obstacle considéré comme le plus alarmant. Si l'on suppose que l'observateur et la cible se déplacent longitudinalement alors les données nécessaires au fonctionnement de l'ACC sont limitées. En effet, on aura besoin essentiellement de la vitesse et de la distance relative de l'obstacle. Par contre, dans un contexte de gestion des interdistances en virage, la position latérale de la cible est une information pouvant devenir indispensable. Les informations des capteurs ne sont pas nécessairement des mesures de position, et en particulier de position latérale. On verra, par exemple, que pour notre radar il est difficile, voire même impossible, d'estimer la position relative latérale des obstacles puisque ses mesures ne sont que radiales et que l'on laisse au conducteur le soin d'effectuer les manoeuvres latérales. Cependant, l'ajout d'hypothèses permettra éventuellement d'obtenir une

estimation "grossière" de la trajectoire et/ou de la position latérale. Tout le monde sait, que le capteur GPS, est un senseur qui s'intègre facilement dans les véhicules routiers et que sa précision de positionnement ne cesse d'augmenter (précision de l'ordre de 5 centimètres pour des GPS différentiels<sup>9</sup> performants). En outre, de nombreuses cartographies existent. Par exemple, certaines cartes proposent une cartographie précise de tous les éléments de la route (lignes blanches, pointillés, passage piéton, feux tricolores, barrière de sécurité, arbres, ...). Les figures 1.22 et 1.23 sont des exemples de cartes précises d'un boulevard de l'agglomération clermontoise.



*Figure 1.22* — Une carte détaillée d'un boulevard

A partir de l'estimation de position, il sera donc facile de savoir où la cible se trouve sur la route, et en particulier d'accéder à la courbure et la largeur de la route à l'endroit considéré. De plus, si un système performant est capable de reconnaître l'obstacle que l'on suit (ce sera l'hypothèse la moins probable), on pourra accéder à d'autres informations comme la vitesse angulaire du cap du véhicule. Pour la reconnaissance, on pense par exemple à un système de vision capable de reconnaître dans une base de données un certain nombre de véhicules. A partir de cette hypothèse, qui je l'admets est forte, on pourra par l'étude de la dynamique longitudinale proposer des bornes sur l'accélération, et par l'étude de la dynamique latérale une estimation de la vitesse angulaire du cap et de l'angle latéral

---

<sup>9</sup>DGPS




Figure 1.23 — Une carte détaillée d'un boulevard

de dérive. On verra, que l'ajout de ces hypothèses permet une estimation de la position latérale à partir de l'observation de mesures radiales seules. Néanmoins, l'ajout d'un capteur laser ou autre (vision, ...), permettant d'obtenir une observation précise de position permet la suppression de ces hypothèses. On est maintenant dans un contexte de fusion. Dans notre cas, le capteur radar délivre des données précises en vitesse (de l'ordre du  $km/h$ ) et imprécises en distance (porte de  $22.5 m$ ); le traitement des données du capteur lidar permet d'obtenir une mesure de position précise ( $\approx 10 cm$  pour le lidar) toutes les  $\approx 500 ms$ . Un des buts de la fusion sera donc d'estimer de façon précise la position de la cible à la fréquence du capteur le plus rapide, soit  $8 ms$  dans notre application. De plus, on verra que le degré de reconnaissance est nul pour les observations radar. Il sera donc difficile, par exemple, de faire la différence entre un véhicule arrêté et une barrière de sécurité. L'autre but de la fusion sera donc de prendre des décisions sur les pistes générées par les différents traitements capteurs. Par exemple, si une piste appartenant au champ de recouvrement des faisceaux des deux capteurs n'est vue que par un seul capteur alors faut-il prendre la décision d'éliminer cette piste ?

### 1.3 Estimation des caractéristiques cinématiques des obstacles

En préambule, il faut souligner le fait que la fusion d'informations est un cas d'estimation. On pourra même considérer l'estimation comme un cas de fusion. La loi de Bayes confirme cette affirmation puisqu'elle fusionne des informations a priori et a posteriori. De même le filtrage récursif peut être considéré comme la fusion d'une prédiction et d'une observation courante.

L'estimation des caractéristiques des obstacles se base sur le "design" et l'évaluation d'algorithmes d'estimation d'état qui opèrent dans un environnement stochastique. Ces méthodes sont des systèmes d'extraction d'information pour la détection d'objets en mouvement à partir d'observations capteurs. Le but est donc de mettre en phase les propriétés physiques de l'objet d'intérêt et des capteurs avec les paramètres d'un modèle mathématique, à savoir la caractérisation statistique d'un processus aléatoire décrivant les incertitudes du problème. Même si la combinaison d'informations issues de différentes sources est un domaine en pleine expansion, on doit garder en mémoire que l'extraction d'information est un pas crucial avant la fusion. De plus la fusion doit tenir compte des incertitudes existantes afin de quantifier la précision de l'information à fusionner. En prélude à l'estimation d'état, l'estimation de paramètres est abordée afin de montrer le concept de limite d'information extractible d'un système et d'estimer des paramètres déterministes décrivant les trajectoires de l'obstacle. L'estimation est vue ici comme le processus d'inférence de la valeur d'une quantité d'intérêt à partir d'observations non précises, incertaines.

Le pistage est l'estimation de l'état d'un objet en mouvement basée sur des observations capteurs. Au premier abord, le "tracking" peut être ressenti comme un cas d'estimation. Cependant, non seulement il utilise les outils de l'estimation mais il nécessite l'utilisation de la théorie statistique de décision quand des problèmes pratiques (association de données - Est ce que c'est ma mesure ?) sont considérés.

Le filtrage est quant à lui l'estimation de l'état courant d'un système dynamique. Le terme filtre est utilisé ici parce que l'on doit obtenir le meilleur estimé à partir de mesures bruitées (élimination d'un signal non désiré).

En résumé, on peut dire que l'on cherche à maximiser notre connaissance sur un paramètre ou un état. On peut donc classer les variables à estimer en deux catégories :

- paramètres (scalaire, vecteur, matrice)

- état d'un système dynamique (vecteur) qui évolue dans le temps à partir d'une équation stochastique

Cette classification implique l'utilisation de deux classes d'estimateurs :

- estimation de paramètres
- estimation d'état

Les résultats, en terme de convergence et de limite d'information extractible, sont plus facilement disponibles pour les estimateurs de paramètres que pour les estimateurs d'état. Les modèles mathématiques à appliquer afin de résoudre les problèmes pratiques seront donc choisis à partir de l'étude de l'estimation de paramètres.

La figure 1.24 présente un diagramme qui illustre l'estimation d'état. Sur cette figure les deux premiers blocs sont des boîtes noires : on n'a pas accès aux variables leur appartenant. Les seules variables auxquelles l'estimateur a accès sont les mesures affectées par les erreurs des sources (bruit de mesure).

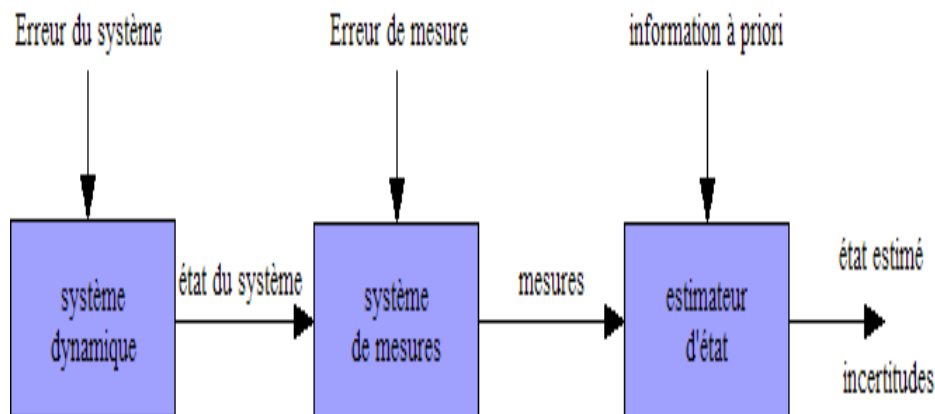


Figure 1.24 — Estimation d'état

L'estimateur utilise la connaissance de :

- évolution des variables (dynamique du système)
- le modèle de mesure
- la caractérisation probabiliste des facteurs aléatoires
- l'information à priori

## 1.4 Conclusion

La perception à bord des véhicules routiers intelligents a pour but de résoudre les problèmes liés à la détection d'obstacles, à la reconnaissance et reconstruction de la route et de la signalisation, à la localisation de la chaussée. Tous ces enjeux sont caractérisés par de nombreux projets dont l'un des plus fédérateurs en France est sans doute le projet ARCOS. Ce projet vise à réduire le nombre d'accidents sur la route. Il s'appuie sur l'approche triangulaire "infrastructure-véhicule-conducteur" afin d'organiser la perception de manière globale. Les systèmes perceptifs développés sont basés sur l'utilisation de capteurs intégrables dans des plateformes expérimentales. Ces plateformes sont nombreuses et de qualités et sont indispensables pour démontrer les résultats. Les capteurs sont quant à eux basés sur des technologies différentes. On parlera du côté des capteurs extéroceptifs de caméras, de laser ou de radar. Cependant, tous ces capteurs ne sont pas aptes à percevoir de manière rapide, robuste et précise dans toutes les circonstances l'ensemble de l'infrastructure s'ils travaillent de manière indépendante. La multiplication des sources de données est donc la clef pour une perception complète de l'environnement. Pour la détection d'obstacles à l'avant d'un véhicule, on verra que le radar semble être le capteur indispensable à un système multisensoriel puisqu'il est un des seuls à fonctionner de manière valide dans des circonstances critiques pour la sécurité du conducteur (brouillard en particulier). Dans la suite, le signal radar sera utilisé dans les deux applications proposées (combinaison radar/laser et combinaison radar/IR). L'utilisation du signal laser (ou de l'infrarouge) permet d'avoir une bonne résolution latérale, et le degré de reconnaissance des obstacles est supérieure à celui du radar. Dans le chapitre suivant, on s'intéressera à la description des capteurs formant notre système et en particulier à l'extraction des observations laser, radar et infrarouge, à partir de leurs signaux respectifs.

## Chapitre 2

# DESCRIPTION DES CAPTEURS ET PRETRAITEMENT

La détection d'obstacles est donc un des problèmes clefs de la robotique mobile. Chaque robot mobile devant évoluer dans un environnement inconnu doit être capable de détecter les obstacles. Selon J. Hancock, la détection d'obstacles ne sera jamais un problème résolu [47]. En effet, les robots mobiles deviennent de plus en plus capables et évoluent à des vitesses qui ne cessent d'augmenter ; ces robots auront donc besoin d'observer plus loin, d'examiner de plus larges zones et nécessiteront des laps de temps de plus en plus court. De plus, la population apparaissant de plus en plus dépendante de ces systèmes, il paraît nécessaire de faire accroître leur fiabilité. Du côté des véhicules routiers intelligents, plus les systèmes sont devenus capables, plus l'attention s'est focalisée sur le problème de la détection d'obstacles. Ces systèmes résultant pour la plupart de collaborations nombreuses et de qualité. De nombreuses recherches ont été menées depuis une vingtaine d'années dans différents pays sur les moyens de réduire le nombre de collisions sur route. La figure 2.1 montre la répartition des causes d'accident. Un peu moins de la moitié des accidents est due à une erreur humaine caractérisée par une erreur de perception de l'environnement. Un peu plus du tiers est due à des causes extérieures comme l'état de la route. Seize pour cent sont dus à une défaillance du conducteur (endormissement,...), et enfin un pour cent à des causes liées à la voiture. La figure 2.2 montre que la majorité des accidents graves (tués ou blessés graves) résulte des collisions avec des obstacles. Il est donc nécessaire pour une bonne perception de détecter ces obstacles et d'en



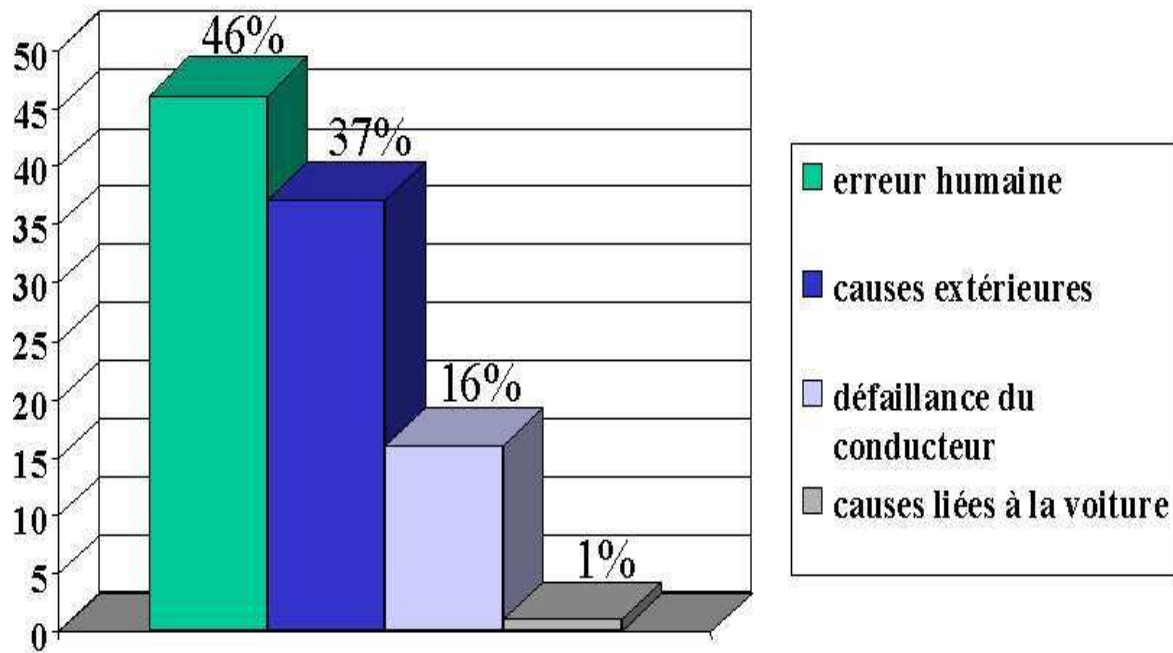


Figure 2.1 — Répartition des causes d'accident




Figure 2.2 — Types d'accidents

extraire des informations importantes pour la sécurité du conducteur. Envisagée comme une aide à la conduite, la détection d'obstacles est donc une fonction vitale à examiner pour la réduction de l'accidentologie. La détection d'obstacles est, dans un contexte de sécurité routière, un outil au service de fonctions dont la terminologie est plus précise (anticollision, collision mitigation<sup>1</sup>, ...). Actuellement, la recherche sur les véhicules intelligents a fait d'énormes progrès conduisant à une réelle autonomie de ces derniers. L'apparition de nombreux systèmes intégrés aux véhicules routiers tels que le suivi de route, le maintien du cap, la détection d'obstacles montre ce réel progrès.

Précédemment, on a vu que les plateformes expérimentales utilisaient de nombreux capteurs extéroceptifs et proprioceptifs. En effet, un environnement routier est une scène complexe à analyser, dépendante de nombreuses circonstances (météo, état de la chaussée, luminosité, conducteur, vitesse). Les différents capteurs présentés dans la suite apportent leurs solutions à ces problèmes de perception. Chaque capteur peut résoudre une tâche spécifique. Les télémètres Laser et Radar sont particulièrement adaptés pour la détection d'obstacles. De l'autre côté, les caméras permettent d'effectuer toutes les tâches de perception (reconstruction et reconnaissance de la chaussée, de la signalisation, la localisation du véhicule sur la chaussée, détection d'obstacles). Cependant, leurs performances sont souvent limitées ou restreintes par les conditions expérimentales (météo, lumière, ...). On s'attache donc ici à présenter les capteurs utiles pour la détection d'obstacles. On s'intéressera particulièrement aux capteurs utilisés pour valider les méthodes développées.

## 2.1 La télémétrie laser

### 2.1.1 La place du laser dans les véhicules routiers intelligents

Depuis de nombreuses années, la télémétrie laser est utilisée pour la détection d'obstacles, spécialement pour la navigation en terrain inconnu. La télémétrie laser opère par balayage d'un faisceau dans une région d'intérêt et mesure, pour chaque pixel, le temps mis par le faisceau laser pour partir et revenir au capteur. De nombreuses méthodes pour le calcul du temps de vol sont explicitées dans [47]. De plus, connaissant la position angulaire du tir, on peut en déduire la position exacte de

---

<sup>1</sup>réduction de la vitesse d'impact

l'objet dans un plan. Enfin, aujourd'hui, la plupart des télémètres lasers renvoient l'intensité du signal pour chaque pixel en mesurant l'énergie du signal laser retourné. Donc, un balayage complet en deux dimensions peut donner une image de profondeur et une image d'intensité. Les obstacles peuvent donc être détectés en observant les discontinuités apparaissant dans l'image de profondeur et dans l'image d'intensité.

En 1994, dans [106] les auteurs proposent un système embarqué couplant un télémètre laser à une caméra CCD pour avoir une image d'intensité. Ils détectent premièrement les obstacles dans l'image d'intensité délivrée par la caméra, ensuite le télémètre est utilisé pour valider ou non la présence d'obstacles mais aussi pour obtenir une information de distance des obstacles détectés. Une seconde approche [99], dans laquelle la scène est scrutée par balayage du faisceau laser pour obtenir une image 3D de faible résolution, repose sur la segmentation et l'interprétation des données de profondeur. Dans [21], différentes méthodes de segmentation d'images de profondeur sont présentées.

Plus récemment, J. Hancock [47][48] démontre comment l'intensité du laser peut être utilisée pour détecter les obstacles sur autoroute. En effet, l'intensité du laser fournit des informations différentes des données de vidéo ordinaires puisque les directions d'éclairage et de vue sont coïncidentes. Leur système de détection d'obstacles statiques utilise un scanner laser haute performance qui procure rapidement une ligne de différents scans. L'analyse sous forme d'histogramme de l'intensité laser retournée est utilisée pour sélectionner les obstacles potentiels. Ensuite, après avoir mis en correspondance les candidats des lignes précédentes, la distance de chaque obstacle est estimée. Finalement, la position de chaque obstacle est mise à jour, avant que la prochaine ligne soit acquise, en se basant sur le mouvement du véhicule. Ils détectent facilement toutes sortes d'obstacles (cageot de bois, parpaing, réverbère, voiture) jusqu'à 35 m. La plupart de ces obstacles apparaît détectables à des distances de 50 m ou plus en utilisant une bonne configuration des différents paramètres. En particulier, ce système est capable de détecter un parpaing à une distance de 60 m.

D'autres méthodes récentes utilisant la télémétrie laser sont présentes dans la littérature [29, 36, 41, 60, 76]. Dans [60], les auteurs combinent les données d'estimation des bords de la route (barrière de sécurité, borne réfléchissante) et les données de détection des obstacles pour avoir une estimation plus robuste et plus précise de la situation dans le trafic (position, vitesse des obstacles) jusqu'à une distance maximale de 100 m. Un capteur, utilisant la télémétrie laser (haute portée 150 m), est proposé dans [36, 41]. Ce capteur retourne une image de profondeur haute résolution, et utilise une méthode

de détection d'obstacles basée sur la segmentation et un algorithme de tracking pour envoyer via une interface CAN<sup>2</sup> les informations (vitesse, taille) concernant les différents objets détectés. Dans [29], les obstacles détectés (jusqu'à 100 m) sont différenciés par segmentation des images de profondeur et par utilisation de modèles (voiture, camions/bus, moto/vélo, petits objets dynamiques).

### 2.1.2 Le télémètre laser LMSZ210-60 du LASMEA

Le télémètre Laser 3D LMSZ210-60 Riegl (voir figure 2.3) est un système capable de délivrer des images 3D. Ces images sont basées sur la mesure de distance précise délivrée par un système opto-électronique et sur un mécanisme à double balayage. Elles sont formées en exécutant une série de mesure de distance dans des positions différentes, avec des directions angulaires bien définies. Ces données de distance associées aux angles forment la base des images 3D. Ces images 3D ou de profondeur se présentent sous la forme de matrice par analogie avec les images de luminance. Chaque élément de la matrice représente un pixel. Chaque pixel donne une information sur la scène observée par le capteur 3D. Cette information représente une indication de position dans la scène. En résumé, l'information contenue par chaque pixel de l'image de profondeur représente les coordonnées géométriques de celui-ci dans le repère du capteur.

#### 2.1.2.1 Le module de mesure de distance

Le système de mesure de distance est basé sur le principe du calcul de temps de vol des impulsions laser de longueur d'onde dans le proche infra-rouge.

Un générateur d'impulsions électriques commande une diode laser semiconductrice qui envoie des impulsions de lumière infrarouge vers un objectif émetteur. A travers l'objectif récepteur, une partie du signal réfléchi par une cible frappe une photo diode, ce qui génère un signal électrique. L'intervalle de temps entre l'émission et la réception est mesuré au moyen d'une fréquence d'horloge stabilisée par un quartz. La mesure de distance calculée est transmise à un microprocesseur interne qui prépare les données à transmettre au PC (voir figure 2.4).

---

<sup>2</sup>Controller Area Network



Figure 2.3 — Le télémètre laser LMSZ210-60

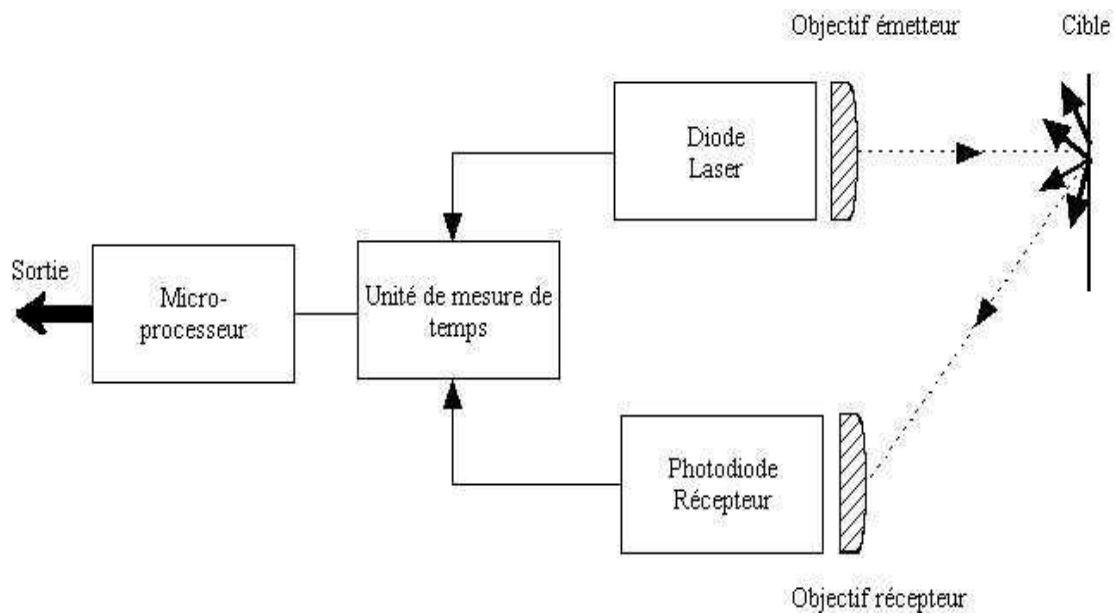


Figure 2.4 — Principe de mesure de distance

### 2.1.2.2 Le module de balayage

La tâche du mécanisme de balayage est de diriger le faisceau laser dans une position précise définie. Les images 3D (appelée aussi frame) sont composées de lignes, et chaque ligne est composée de pixels. Ce mécanisme fournit un balayage rapide pour les lignes, et plusieurs centaines de pixels par ligne. Le mécanisme de balayage pour les frames est beaucoup plus lent que celui pour les lignes. La déflexion angulaire du faisceau laser est réalisée par un miroir polygonale rotatif (voir figure 2.5). Les miroirs polygonaux sont habituellement en rotation à vitesse constante afin de fournir des balayages répétitifs unidirectionnels. Le nombre de facettes du polygone rotatif fixe l'amplitude de l'angle de déflexion. Notre laser est équipé d'un miroir polygonal rotatif à quatre facettes ( $60^\circ$ ). Un faisceau laser à diamètre constant est divisé au niveau de l'arête du polygone en deux faisceaux se propageant dans différentes directions. Par conséquent, la révolution complète ne pourra pas être utilisée pour le balayage et le secteur utilisable de balayage doit être réduit. Le mécanisme de balayage formant les images, plus lent que celui des lignes, se fonde sur la rotation du système formé par la tête optique et le balayage des lignes. Ceci est accompli en montant le système de balayage des lignes et la tête optique sur un système tournant.

### 2.1.2.3 Spécifications du capteur

Les performances et caractéristiques du capteur sont résumées dans les tableaux suivants (tableau 2.1 2.2 2.3).

Toutes ces caractéristiques sont adaptées à notre application. En effet, la gamme de mesure est appropriée à la détection d'obstacles routiers et la divergence permet d'obtenir une résolution satisfaisante (  $1 \text{ mrad}$  correspond à un impact de  $10 \text{ cm}$  de diamètre à  $100 \text{ m}$ ).

### 2.1.2.4 Définitions des axes

La figure 2.6 décrit le repère absolu lié au capteur qui sera utilisé dans la suite.




Figure 2.5 — Principe du balayage du faisceau laser avec un miroir rotatif

Mécanisme de balayage	miroir polygonale rotatif
Nombre de facettes	4
Angle de balayage	60° fixé
Mouvement angulaire	linéaire, unidirectionnel
Vitesse de balayage	5 balayages/s → 90 balayages/s
Pas angulaire	0.072° → 0.57°
Résolution angulaire	0.036°

*Tableau 2.1* — Caractéristiques de balayage des lignes

Mécanisme de balayage	tête optique rotative
Angle de balayage	0° → 333° fixé
Mouvement angulaire	linéaire
Vitesse de balayage	1°/s → 20°/s
Pas angulaire	0.072° → 0.36°
Résolution angulaire	0.018°

*Tableau 2.2* — Caractéristiques de balayage des images

Mesure de distance	0.5m → 150m
Résolution	±25mm
Précision	2.5cm
Cadence de tirs	→ 28kHz
Longueur d'onde	proche infrarouge 0.9μm
Divergence du faisceau	3mrad
Sécurité laser	classe 1

*Tableau 2.3* — Caractéristiques du laser pour la mesure de distance






Figure 2.6 — Le repère absolu lié au capteur

### 2.1.2.5 Caractéristiques temporelles

Les caractéristiques temporelles du capteur correspondent au temps nécessaire au capteur pour acquérir une image 3D de la scène. Ce temps est lié à la vitesse de rotation maximale de la tête optique ( $20^\circ/\text{s}$ ) et à la vitesse de rotation maximale du miroir polygonal rotatif à quatre facettes (90 lignes/s soit  $90/4=22.5\text{tours/s}$ ). Ces vitesses fixent donc une contrainte sur le pas angulaire à ne pas dépasser pour le balayage des lignes. Le temps  $t$  nécessaire pour acquérir une image 3D complète est donnée par :

$$t = \frac{\alpha}{\omega}$$

où  $\alpha$  est l'angle total fixé par le nombre de lignes et  $\omega$  est la vitesse angulaire de la tête optique. Déterminons le temps nécessaire pour acquérir une image 3D de 100 pixels par 20 lignes le plus rapidement possible. Ce type d'images 3D sera le type d'images utilisé dans notre système de perception. Ses dimensions correspondent, après différents tests, aux dimensions minimales en vue d'une détection aisée des obstacles. Le tableau 2.4 montre les différents paramètres du capteur et leurs contraintes associées. On déduit, de ces différentes données, le temps d'acquisition théorique. On remarque que le temps réel d'acquisition est supérieur au temps d'acquisition théorique. Cette supériorité est due au temps que le moteur de la tête optique met pour réaliser un aller-retour et au

		contraintes
nb lignes/image	20	
angle total pour une image	4650 mrad	
pas angulaire entre deux lignes	244,7 mrad	< 245,5 mrad
nb pixels/ligne	100	
angle total pour une ligne	63360 mrad	
pas angulaire entre deux pixels	640 mrad	
vitesse du polygone rotatif	22,4 tours/s	< 22,5 tours/s
nb lignes/sec	89,6	90
vitesse angulaire de la tête optique	21,9 rad/s	22 rad/s
	19,7°/s	20°/s
temps d'acquisition théorique	212 ms	
temps d'acquisition réel	512 ms	

*Tableau 2.4* — Caractéristiques temporelles du laser

fait que la "théorie" n'englobe pas tous les paramètres. C'est une contrainte mécanique impossible à supprimer.

Des exemples d'images 3D délivrées par ce capteur sont donnés dans la suite.

### 2.1.2.6 images 3D ou frames

Nous présentons ici différents types d'images 3D en insistant sur les images utilisées dans notre système de détection d'obstacles. Les premières images correspondent à une image dense d'un bureau. Elles correspondent à une rotation de la tête optique de 333° et un angle de balayage de 60° (fixe). L'image 2.7 est une représentation de l'image 3D par code couleur (couleurs différentes par classe de distance). L'image 2.8 correspond à l'image d'intensité laser reçue par le capteur. L'image




Figure 2.7 — Image 3D dense : un bureau



Figure 2.8 — Image d'intensité dense : un bureau




Figure 2.9 — Une vue 3d du bureau au format vml

en 3 dimensions 2.9 permet de tourner autour d'un objet avec la souris, de le déplacer, de s'en rapprocher, comme s'il était réel. Elle permet aussi la vision panoramique, par exemple d'un paysage ou la visite virtuelle d'une maison ou d'une auto.

Nous présentons maintenant différentes images, utilisées dans notre système de perception, dont les dimensions sont 102 pixels  $\times$  20 lignes. La dimension des images est fixée par les caractéristiques temporelles du capteur (une image toutes les 500ms). Nous proposons différents types d'images correspondant à plusieurs types d'obstacles (voitures : figure 2.10, camions : figure 2.11, motos : figure 2.12, piétons : figure 2.14). Pour toutes ces figures l'image du haut correspond à l'image d'intensité laser retournée par le capteur, l'image du milieu représente l'image 3D avec un code couleur (la couleur dépend de la distance de chaque point 3D, la couleur blanche correspond aux impacts non définis) et enfin l'image du bas représente la vue de la scène.

Ces différentes images montrent premièrement qu'il n'est pas possible d'utiliser l'intensité laser






Figure 2.10 — visualisation d'une voiture à 30m

reçue par le capteur en vue de la détection d'obstacles. En effet, elles ne permettent pas une bonne discrimination des obstacles. Cette donnée ne sera donc pas utilisée dans la suite. De plus, dans des conditions de brouillard on s'aperçoit que le télémètre laser ne délivre pas de mesures pour un obs-



*Figure 2.11* — visualisation d'un camion à 50m



*Figure 2.12* — visualisation d'une moto à 10m




Figure 2.13 — visualisation d'un piéton à 11m




Figure 2.14 — visualisation d'un obstacle à 40m dans le brouillard



tacle situé au-delà de 40 m. Ensuite, on remarque qu'il existe une assez bonne discrimination des obstacles dans les images de profondeur ce qui permettra une détection correcte.

La méthode de détection et de reconnaissance des obstacles sera décrite dans la suite.

## 2.2 Le Radar

### 2.2.1 La place du dans les véhicules routiers intelligents

Initié par AEG Telefunken en Allemagne en 1973 à 35 GHz, le projet de radar hyperfréquence a été relancé par le programme européen Promothéus avec une version à 77 GHz vingt ans plus tard. Les bandes de fréquences réservées aux transports routiers sur chaque continent sont données sur le tableau 2.5. La bande de fréquence 76 – 77 GHz est la plus commune pour les projets radar

Bandes de fréquences supportées	Organisation
76 – 77 GHz	CEPT (Europe)
76 – 77 GHz	ETSI (Europe)
46,7 – 46,9 GHz, 76 – 77 GHz	FCC (USA)
60 – 61 GHz, 76 – 77 GHz	MPT (Japon)

*Tableau 2.5* — Bandes de fréquences allouées aux radars automobiles longue portée

anti-collision. Fondamentalement, un radar doit permettre de détecter l'obstacle mobile ou non et de calculer la distance le séparant du véhicule intelligent. Dans cette optique, les radars à ondes hyperfréquences peuvent être divisés en deux grandes catégories : les radars impulsionsnels d'une part, les radars à émission continue et à modulation de fréquence d'autre part.

Pour les radar impulsionsnels, on s'attache à déterminer le temps écoulé entre, l'écho provenant de l'obstacle détecté et le signal émis. On peut à nouveau distinguer deux familles, selon que la détection du signal réfléchi par l'obstacle est cohérente ou non. Les modèles à détection non cohérente sont les plus simples à réaliser, mais ne permettent pas d'évaluer la vitesse de la cible (pas de mesure de phase), et ne permettent donc pas de développer tous les types d'applications désirés. Le second type (à détection cohérente) résout ce problème en permettant d'avoir une relation entre la phase du signal émis et celle du signal réfléchi par la cible. Pour les radar à émission continue et à modulation

de fréquence, il s'agit de déterminer le décalage en fréquence entre l'écho provenant de l'obstacle détecté et le signal émis. Le radar est alors structuré autour d'un oscillateur contrôlé en tension, qui sert tant en émission qu'en réception. Il permet en effet à la fois de transmettre le signal à l'antenne en assurant un bon contrôle de la fréquence, et de passer en fréquence intermédiaire le signal reçu. La spécificité du récepteur est donc que son fonctionnement n'est basé que sur un multiplieur. Le signal en fréquence intermédiaire étant ensuite simplement amplifié, et transféré à une unité de traitement. Cette simplification de la partie hyperfréquence entraîne donc un accroissement de la partie de traitement du signal en réception, mais ceci va de pair avec l'évolution des performances des dispositifs de traitement.

Du point de vue automobile, le radar est un excellent moyen pour détecter les autres véhicules puisqu'il travaille à des très grandes portées et puisqu'il n'est pas affecté par la pluie, la neige ou le brouillard [56, 59, 63, 67]. Un type de radar (77Ghz MMW radar) pour la détection d'obstacles est présenté dans [67]. Ce radar est capable de détecter des obstacles jusqu'à une distance de 200m avec une résolution de 0.1m. Ce capteur a un champ de vue vertical de 3° et un champ de vue horizontal de 12°. La position des obstacles est estimée grâce à la reconstruction du front d'onde, et en combinant cette estimation avec l'information géométrique de la route, la position et l'orientation des obstacles potentiels relativement à leur voie sont calculées. Dans [101], un radar courte portée permet de détecter les obstacles à quelques dizaines de centimètres, ce radar n'utilise pas le temps de retard comme les radars usuels mais utilise l'information de phase. Un système ACC utilisant un radar 60.5 Ghz MMW est présenté dans [63]. Ce radar est capable de mesurer la distance, la vitesse et l'angle azimut des véhicules en amont.

Cependant, de manière générale, le radar connaît quelques inconvénients. Les réflexions sur les barrières de sécurité peuvent conduire à des fausses alarmes. Deux véhicules roulant côte à côte à la même vitesse sont difficilement différenciables et peuvent être regroupés en un seul obstacle. Cela signifie, par exemple, qu'une moto derrière un camion pourra être invisible pour le radar. Pour palier ce problème l'utilisation d'un autre capteur est souvent nécessaire [17, 93, 50, 75]. Des méthodes de fusion avec un capteur Laser ou caméra Infrarouge seront présentées dans le chapitre 5.



### 2.2.2 Radar Doppler à priorité Doppler du LASMEA

L'objectif du projet PAROTO est de détecter avec une grande précision les obstacles présents à l'avant du véhicule porteur du système à l'aide des informations fournies par une caméra thermique et un radar. Les principaux intérêts liés à l'utilisation d'un radar dans ce projet sont d'une part la précision sur la vitesse estimée des obstacles et d'autre part son indépendance de bon fonctionnement vis à vis des conditions météorologiques difficiles.

Selon la réglementation en vigueur dans l'Union Européenne et aux Etats-Unis, la fréquence d'émission de l'onde pour un projet d'anti-collision automobile est fixée à  $77 \text{ GHz}$  (radar d'onde millimétrique). Le principe du radar utilisé dans le cadre du projet PAROTO est une fusion entre la technique du radar à impulsions et l'exploitation du phénomène Doppler : c'est un radar Pulse Doppler Priorité Doppler [72, 16]. En effet, la priorité est donnée à l'estimation de la vitesse relative entre le véhicule et les obstacles potentiels. Les distances des obstacles au véhicule porteur du radar sont rangées par classe de distance ou "porte distances".

De plus, ce radar est constitué d'une seule antenne qui sert d'émetteur et de récepteur. Ce procédé nécessite la mise en place d'un circulateur (système hyperfréquence) et d'un processus de synchronisation qui permettent de transférer de l'énergie soit entre l'émetteur et l'antenne soit entre l'antenne et le récepteur (voir figure 2.15). La voie de réception étant très sensible, ce système doit parfaitement isoler la voie de réception de celle d'émission.

#### 2.2.2.1 Bilan de puissances

L'expression de la puissance moyenne du signal en réception en fonction de la puissance émise  $P_e$ , pour une cible placée à la distance  $D$  ayant une section efficace  $\sigma$  avec une antenne émission/réception de gain  $G$  est donnée par [92] :

$$P_r = P_e G^2 \lambda^2 \frac{\sigma}{(4\pi)^3 D^4}$$

où  $\lambda$  est la longueur d'onde utilisée (3,9 mm).

La section efficace ou surface équivalente radar (SER) traduit en fait la portion de surface "éclairée" par le faisceau directif incident. Elle a les dimensions d'une surface. C'est une caractéristique de la cible (type de matériaux de surface, etc) qui représente une mesure de sa taille vue par le radar. La section efficace d'une automobile vue par un radar est approximativement de  $100 \text{ m}^2$ . La technique

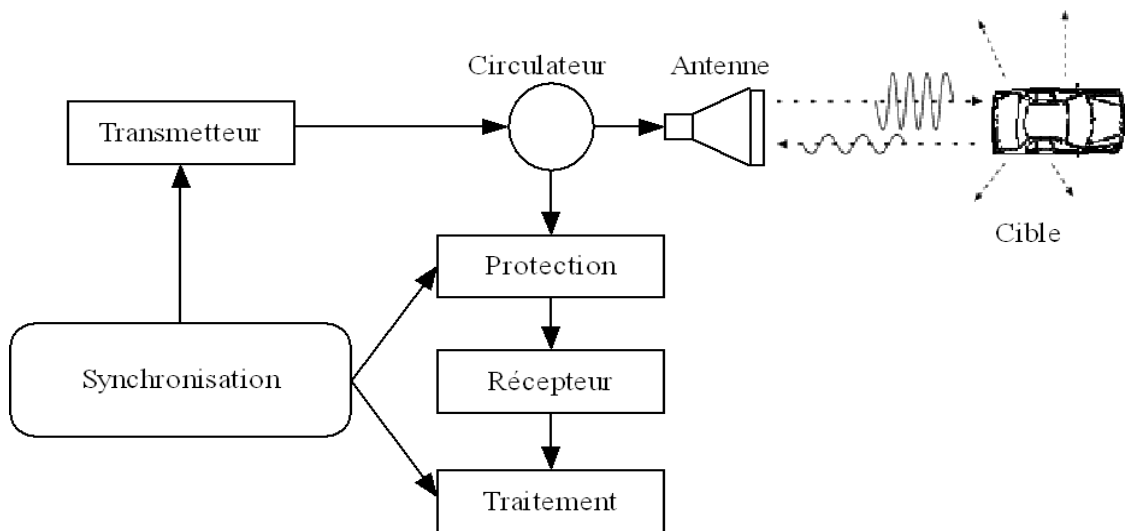


Figure 2.15 — Structure du radar PAROTO à une antenne

radar employée dans ce projet consiste à envoyer par impulsions répétitives (de largeur  $t_e = 150 \text{ ns}$  et de période  $T_r = 4 \mu\text{s}$ ) une onde électromagnétique sinusoïdale et recevoir les échos pour l'analyse (voir figure 2.16). Le bilan de puissances est donc réalisé en utilisant la puissance moyenne  $P_m$  du signal sur une période de répétition soit :

$$P_m = P_e \frac{t_e}{T_r}$$

Pour une puissance  $P_e$  de  $3 \text{ mW}$ , un gain d'antenne de  $26 \text{ dB}$ , une distance de  $D = 150 \text{ m}$  et avec une section efficace de  $1 \text{ m}^2$  (SER d'un panneau par exemple), la puissance moyenne du signal reçu par le radar est égale à  $3.10^{-13} \text{ mW}$  d'où l'importance d'une isolation efficace entre l'émetteur et le récepteur.

### 2.2.2.2 Le signal Radar

La relation reliant le signal de réception au signal d'émission peut s'exprimer simplement dans le cas d'un seul écho (considéré comme ponctuel) en provenance d'un objet situé sur le trajet de




Figure 2.16 — Diagramme d'émission et de réception

l'onde émise à la distance  $D$ , de vitesse relative  $v$  dans la direction de l'axe radar-objet. Pour le radar impulsionnel qui nous concerne, le signal complexe d'émission est de la forme :

$$e(t) = A_e u(t) \exp(j2\pi f_0 t)$$

L'amplitude  $A_e$  de ce signal est directement proportionnelle à la racine carrée de la puissance d'émission  $P_e$  introduite dans le paragraphe précédent, la forme de l'impulsion de durée  $t_e$  est introduite dans la quantité  $u(t)$  (impulsion normalisée).  $f_0$  représente la fréquence radar (77 GHz dans notre cas). Le signal de retour pour un seul écho sera le signal d'émission décalé en première approximation d'un temps  $\tau(t)$  donné par la relation :

$$\tau(t) = 2\frac{D}{\lambda f_0} - 2\frac{v}{\lambda f_0} t$$

soit :

$$s(t) = A_r u(t - \tau(t)) \exp(j2\pi f_0 (t - \tau(t))) \quad (2.1)$$

L'amplitude  $A_r$  est proportionnelle à la racine carrée de la puissance de réception  $P_r$  et pour tenir

compte du diagramme de rayonnement de l'antenne [71] (voir figure 2.17) on introduit une fonction normalisée  $G(\theta, \phi)$ ,  $\theta$  et  $\phi$  représentant les angles définissant la position de l'objet par rapport à l'axe de l'antenne. On mesure en fait l'amplitude complexe du signal qui dépend principalement :

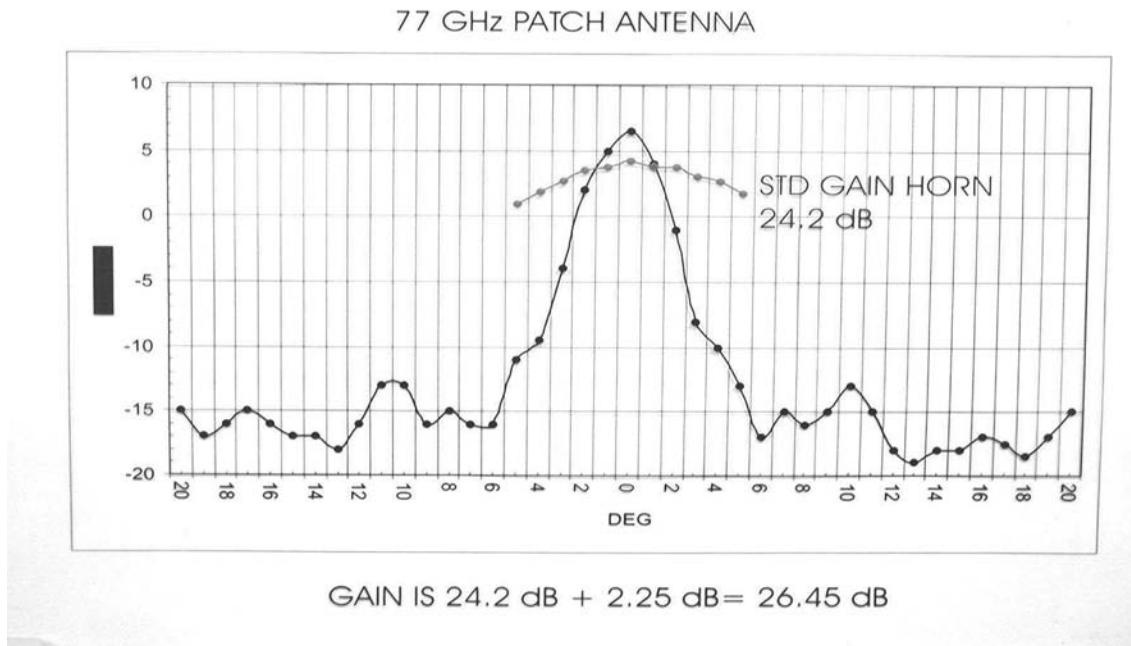


Figure 2.17 — Diagramme d'antenne Radar constructeur

- de la position du signal de réception par rapport à l'instant d'origine de l'impulsion d'émission  $2\frac{D}{\lambda f_0}$ ,
- de la fréquence Doppler :  $f_d = 2\frac{v}{\lambda}$ ,
- du type d'objet caractérisé par sa SER et de sa position par rapport à l'axe de l'antenne.

Dans le cas de plusieurs objets, le signal de réception est la somme des signaux individuels. Pour obtenir la fréquence Doppler, on observe les variations de l'amplitude des échos en répétant le signal d'émission à la période notée  $t_r$ .

### 2.2.2.3 Mise en œuvre du Radar PAROTO

Le LASMEA et la société RCS<sup>3</sup>, société partenaire dans la construction du radar, ont réalisé conjointement ce radar en conformité avec le brevet "Anticollision method for vehicle"[40]. Ce radar est un système traditionnel Pulse Doppler (voir figure 2.18). Il comporte :

- une antenne
- un circuit radio fréquence conventionnel caractéristique d'un radar Pulse Doppler
- deux canaux de sorties I et Q (en quadrature de phase)
- une unité d'acquisition et de traitement qui inclut un convertisseur analogique/digitale
- un calculateur numérique
- un module de détection
- un module de décision pour indiquer au conducteur une situation dangereuse.

De nombreux systèmes capables de réaliser les mêmes fonctions sont connus [108, 89, 62, 73, 26].

---

<sup>3</sup>Radar Communications Services, Chartres (France)

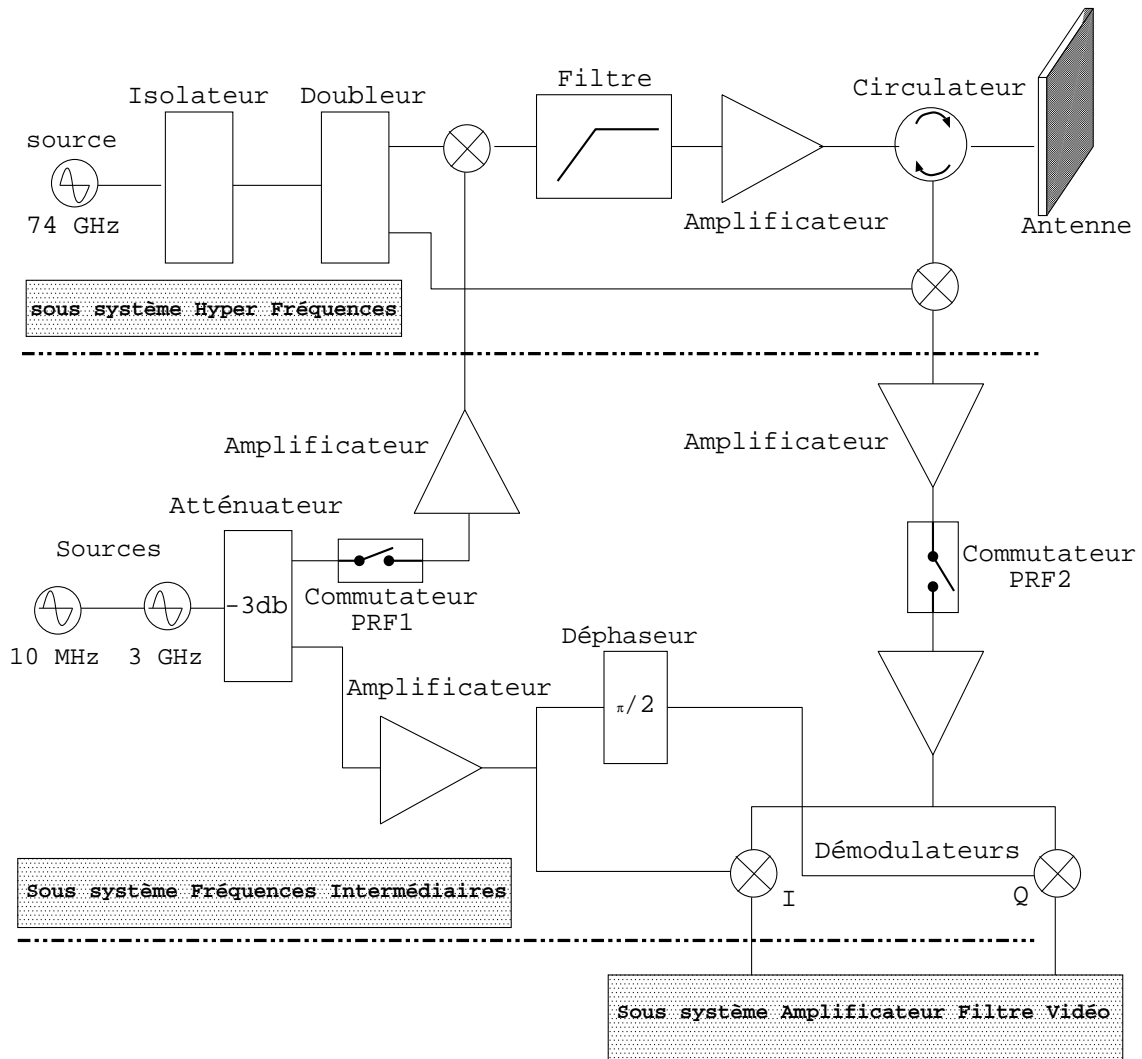


Figure 2.18 — Structure du radar PAROTO

### 2.3 Un exemple de caméra thermique : la caméra PAROTO (Sagem)

On présente ici le capteur infrarouge utilisé dans le projet PAROTO par SAGEM.

Les caméras thermiques de type non refroidi ont des coûts ou des projections de coût qui permettent de les envisager dans les applications automobiles de grande diffusion. Elles sont d'ailleurs déjà intégrées dans des véhicules de haut de gamme (par exemple Cadillac De Ville) afin de fournir au conducteur des images infrarouge (IR) transposées dans le visible et ainsi aider à la conduite dans des conditions de visibilité réduite. Les caméras thermiques par leur sensibilité à des faibles différences de température ou d'émissivité ont dans le domaine automobile une aptitude particulière pour la détection (différence de contraste) des pots d'échappements, des roues et des compartiments moteurs des automobiles, des motocycles, des piétons, des animaux,... En outre, ces capteurs sont insensibles aux conditions d'éclairage (jour, nuit, couleur, ombre, reflet, ...). Les caméras thermiques peuvent certes fournir une image à des fins de visualisation mais aussi à des fins de traitement d'images pour réaliser une détection et un suivi automatique de divers objets.

Le capteur utilisé dans le projet PAROTO est à base de micro-bolomètre non refroidi sensible dans la bande  $8 - 12 \mu m$  (voir figure 2.19). Sa résolution thermique est de 80 mK ; les dimensions de l'image sont  $320 \times 240$  pixels ; l'optique associée permet d'avoir un champ de  $40^\circ \times 30^\circ$ .



Figure 2.19 — Caméra thermique PAROTO

La méthode développée se concentre sur la détection de véhicules, de cycles et de piétons. La Figure 2.20 montre l'aspect de ces derniers en thermique. Les roues et l'échappement sont, en infrarouge thermique, les parties les plus significatives des véhicules motorisés. Idéalement, les piétons apparaissent comme des régions uniformément chaudes. En réalité, l'aspect thermique des piétons dépend des vêtements portés. Toutefois, la tête et les mains restent le plus souvent chaudes.




Figure 2.20 — Aspects thermiques des usagers de la route

## 2.4 La vision

Depuis de nombreuses années, des systèmes utilisant la vision ont été développés pour la détection d’obstacles. En vision, le critère utilisée pour la détection d’obstacles dépend fortement de la définition que l’on fournit pour un obstacle (voir figure 2.21, [14]). Des systèmes confondent




Figure 2.21 — La définition d’un obstacle

la détection d’obstacles avec la localisation de véhicules, qui est basée sur la recherche de formes spécifiques (” bounding box ”, modèle, symétrie,...). Dans la littérature, les informations image uti-



lisées pour la détection par vision de véhicules sont les suivantes :

- texture
- symétrie horizontale
- couleur
- ombre portée
- segments
- route

Tous ces indices sont évoqués et commentés suivant leur exploitation possible, leurs défauts éventuels par rapport à la détection de véhicules, dans [24]. Tous ces systèmes sont basés sur l'analyse d'une seule image, mais malheureusement cette approche n'est plus satisfaisante quand l'obstacle ne correspond plus aux formes spécifiques.

Une définition plus générale, rendant de toute évidence les algorithmes proposant des solutions de plus en plus complexes, est : tout objet sur la chaussée est un obstacle. Cependant, cette définition peut sembler incomplète puisque des piétons pourront être des obstacles potentiels même s'ils ne sont pas sur la chaussée [13, 39]. Dans ce cas, la détection d'obstacles est la recherche de l'espace libre dans lequel le véhicule peut évoluer en toute sécurité au lieu d'être la recherche de formes spécifiques. Le problème est donc traité avec des techniques plus complexes dont les plus connues et les plus utilisées sont celles basées sur le traitement de deux ou plus images, telles que :

- l'analyse du flot optique et
- la stéréovision

Dans le premier cas, différentes images sont acquises avec le même capteur à différents instants, tandis que dans le deuxième cas on traite simultanément deux images acquises avec des capteurs différents avec des angles de vues différents. Le flot optique résulte donc du mouvement du capteur d'image relativement à son environnement, et l'information stéréo génère une estimation de profondeur calculée grâce à des correspondances de structures significatives dans l'image, comme les coins ou les bords, extraites de une ou plusieurs images stéréo. Ces techniques devront être suffisamment robustes pour tolérer les bruits causés par les mouvements du véhicule et les dérives dues à la calibration des différentes caméras.

De nombreuses techniques utilisant le flot optique ont été proposées dans la littérature sur la détection d'obstacles [35, 18, 11, 14]. Bien que certaines de ces techniques réussissent à détecter des grands

obstacles statiques, les méthodes utilisant le flot optique sont meilleures pour détecter des objets en mouvement. Un autre véhicule, par exemple, peut être détecté et pisté en utilisant les techniques du flot optique, même s'il a une vitesse relative inférieure à celle du véhicule équipé puisqu'il est toujours en mouvement par rapport à la route. Ceci peut être compris par la comparaison de la direction du vecteur de flot calculé avec la direction du modèle du vecteur de flot.

De l'autre côté, le traitement des images non-monoculaires nécessite d'identifier des correspondances entre les pixels des différentes images (deux pour la stéréovision). L'avantage d'analyser des images stéréos à la place de séquences d'images monoculaires réside dans la possibilité de détecter directement la présence d'obstacles, qui, dans le cas des méthodes basées sur le flot optique, est indirectement dérivée de l'analyse du champ de vitesse. De plus, dans les conditions limites où l'obstacle et le véhicule ont une vitesse quasiment nulle, les méthodes basées sur le flot optique ne fonctionnent plus tandis que les méthodes basées sur la stéréovision fonctionnent. Dans le domaine des techniques de détection d'obstacles par stéréovision, deux classes de méthodes se distinguent : celles basées sur une mise en correspondance entre les deux images stéréoscopiques, et celles mettant en oeuvre une rectification homographique préalable.

La première technique [12, 4, 61, 84, 20] fournit une carte de disparité, à partir de l'appariement, qui peut être traduite par une carte de profondeur moyennant un calibrage préalable. Une méthode de calibrage automatique qui met à jour les paramètres extrinsèques et la focale est décrite dans [27]. Une sélection des informations selon des critères de cohérence (disparité similaire [64], distance et voisinage spatiale semblable [38]) met, alors, en évidence les obstacles potentiels.

La deuxième technique [49] exploite la transformation homographique qui permet de rectifier une image du système stéréo pour que les pixels, issus de la projection de points sur le plan de la route, se retrouvent à l'identique dans l'autre image. Cette transformation est déterminée a priori, suite à un calibrage préalable du système stéréoscopique. Les objets situés au dessus ou en dessous de la route apparaissent comme étant très dissemblables. La comparaison entre une image et une image transformée par homographie permet ainsi de les mettre en évidence.

La vision propose de nombreuses solutions quant à la détection d'obstacles. Cependant, les limites de capacité sensorielle d'un système de vision sont fixées par les limites de la vision humaine. Les performances de ces capteurs seront donc fortement dégradées dans des circonstances spécifiques (brouillard, nuit, soleil, ...). Ces techniques ne seront donc pas utilisées dans notre système

de perception puisqu'un des objectifs est son indépendance de bon fonctionnement aux conditions météorologiques.

## 2.5 Complémentarités et redondances

Les véhicules intelligents doivent évoluer le plus souvent dans un environnement inconnu. Un seul capteur est capable de ne donner qu'une information partielle et par conséquent sa capacité à interpréter l'environnement est limitée. En effet, tous les systèmes (vision, Radar, Laser) présentent leurs inconvénients respectifs, et la plupart de ces méthodes sont susceptibles de rencontrer des problèmes causés par les conditions de l'environnement dans lequel évolue le véhicule équipé (lumière ou pas, précipitation). Une solution est de multiplier le nombre de capteurs pour obtenir l'avantage des complémentarités et redondances de chaque capteur. Cependant, cette multiplication tend à l'augmentation du flux d'information, ou encore du coût. Il est donc nécessaire d'effectuer un choix qui limite la quantité d'information, pour qu'elle soit transportée et traitée en temps réel. Pour obtenir un bénéfice de ces différents capteurs, il est essentiel que l'information fournie par ceux-ci soit interprétée et combinée pour obtenir une description du système précise, complète, cohérente et robuste. En effet, l'information fournie par un capteur, influencée par les conditions variables de l'environnement (conditions atmosphériques, trafic,...), est le plus souvent géométriquement, temporellement incomparable avec celle fournie par un autre type de capteur. Il est donc nécessaire d'exploiter les complémentarités et les redondances des différents capteurs formant le système multisensoriel (voir tableau ci-après). Les capteurs utilisés dans notre système sont des capteurs passifs et actifs : caméra, caméra IR, télémètre laser, radar. Premièrement, il est évident de souligner que le degré de redondance augmente avec le chevauchement des champs de vision des différents capteurs. Cependant, les performances de chaque capteur sont dépendantes des conditions environnementales telles que les conditions atmosphériques ou le trafic. La vision est sensible aux ombres, à la pluie, à l'illumination, au brouillard. Le télémètre laser est sensible à l'eau, la poussière. Quant au radar, il est insensible aux conditions atmosphériques, ses données sont donc complémentaires avec celles des autres capteurs dans de mauvaises conditions atmosphériques. Le tableau ci-après montrent les complémentarités et redondances des différents capteurs en vue du choix du système de fusion.

	CAMERA	TELEMETTER	RADAR	CAMERA IR
CAMERA	<p><b>Sensibilité aux conditions atmosphériques et environnementales</b></p> <p>ombres (ponts par exemple), lumière éblouissante, pluie, neige, brouillard, nuit, tunnels</p>	<p>rapidité acquisition / pas d'interférences entre véhicules équipés/bas coût / équipement compacte / données moins bruitées / complémentarités si contraste entre obstacle et alentour faible / redondance si détection obstacle avec ces 2 capteurs dans conditions normales / intégration plus aisée / localisation chaussée</p>	<p>champ de vue plus large / meilleur résolution latérale / pas d'interférences entre véhicules équipés/bas coût / meilleur reconnaissance des obstacles / données moins bruitées / redondance si détection obstacle avec ces 2 capteurs dans conditions normales</p>	<p>différenciation des obstacles diffusant la même chaleur / insensibilité jour/nuit, ombres, reflets, couleurs</p>
TELEMETTER	<p>mesure de distance / meilleur positionnement des obstacles sur la chaussée à longue distance / précision de localisation des données de profondeur / information d'angle / montre directement une représentation géométrique de la scène / moins de traitement nécessaire / redondance si détection obstacle avec ces 2 capteurs dans conditions normales</p>	<p><b>Sensibilité aux conditions atmosphériques et environnementales</b></p> <p>forte pluie, poussière, lumière ambiante</p> <p>interférences entre véhicules équipés</p>	<p>champ de vue plus large / meilleur mesure de distance dans conditions normales / meilleur reconnaissance des obstacles</p>	<p>mesure de distance / différenciation des obstacles diffusant la même chaleur</p>
RADAR	<p>mesure de distance / cinématique des obstacles / information d'angle / moins de traitement nécessaire</p>	<p>cinématique des obstacles / intégration plus aisée (absence de parties mobiles) / redondance sur mesure de distance dans conditions normales / rapidité acquisition</p>	<p><b>Sensibilité aux conditions atmosphériques et environnementales</b></p> <p>aucune</p> <p>interférences entre véhicules équipés</p>	<p>mesure de distance / différenciation des obstacles diffusant la même chaleur</p>
CAMERA IR	<p>niveau de reconnaissance supplémentaire / détection des piétons plus facile / pas d'éblouissement en circulation nocturne</p>	<p>rapidité acquisition / détection des piétons plus facile</p>	<p>détection des piétons plus facile</p>	<p><b>Sensibilité aux conditions atmosphériques et environnementales</b></p> <p>pluie, neige, température</p>

Figure 2.22 — Complémentarités et redondances

## 2.6 La détection d'obstacles : extraction des observations

Notre système multisensoriel s'appuie sur l'utilisation de capteurs à technologie différente. On a vu que précédemment le radar semblait être le capteur indispensable pour un fonctionnement selon toutes les circonstances. Cependant, il peut délivrer des fausses mesures et la résolution latérale du signal n'est pas satisfaisante. L'utilisation d'un capteur télémétrique ou d'une caméra infrarouge permet de pallier ces problèmes. On présente donc dans la suite différentes méthodes de détection d'obstacles utilisant des mesures fournies par des capteurs tels que le laser LMSZ210-60, le radar et la caméra infrarouge PAROTO. Le télémètre laser 3D sera utilisé de façon indépendante dans le cadre du projet ARCOS pour les fonctions d'anticollision et de gestion des interdistances. La combinaison des informations radar et infrarouge est la base du projet PAROTO. Outre ces différents projets, on pourra utiliser une combinaison des données télémétriques et radar.

### 2.6.1 Extraction des observations laser

L'extraction de primitives dans les images 3D présentées dans la partie 2.1.2.6 images 3D est une étape de la détection d'obstacles. Cette extraction se déroule en deux étapes et est fondée sur les travaux réalisés dans [99][21]. La première étape consiste en la segmentation en régions de l'image 3D et la deuxième étape réalise la reconnaissance des obstacles parmi ces régions.

#### 2.6.1.1 Segmentation en régions de l'image 3D

L'analyse des images de profondeur est couramment réalisée grâce à des méthodes de segmentation. Ces méthodes bas niveau consistent à regrouper ensemble les pixels présentant des propriétés similaires. De nombreuses méthodes sont présentées dans la littérature. Une description de quelques unes est présentée dans [21]. Pour notre système de perception, le but de la segmentation est d'obtenir des zones formées d'impacts laser spatialement proches. Le critère de segmentation est la distance  $y_a$  car, dans l'hypothèse d'une route plane, les obstacles routiers apparaissent comme des plans orthogonaux à la route constitués de points situés à une distance  $y_a$  constante à une tolérance  $\sigma_y$  près. La méthode retenue pour cette segmentation s'appuie sur un algorithme de croissance de régions. Les régions sont construites à partir d'un impact et croissent en incorporant, de proche en proche, les

impacts situés à la même distance  $y_a$  de notre véhicule avec une tolérance  $\sigma_y$ . Une description du principe de l'algorithme développé dans [99] est donnée ci-dessous.

- tous les impacts sont non classés
  - ⇒ **Pour** chaque impact de l'image de profondeur
    - **Si** distance non nulle et impact non classé
      - initialisation d'une nouvelle régions
      - impact classé
    - ⇒ **Pour** chacun des impacts connexes (voisins)
      - **Si** distance  $y_a$  du voisin égale à  $\sigma_y$  prés **et** impact non classé
        - placer le voisin dans la région
        - placer le voisin dans le tampon de recherche
        - voisin classé
  - FinSi**
    - ↳ **Tantque** le tampon de recherche n'est pas vide
      - ⇒ **Pour** chacun des voisins de l'impact du tampon
        - **Si** distance  $y_a$  du voisin égale à  $\sigma_y$  prés **et** impact non classé
          - placer le voisin dans la région
          - placer le voisin dans le tampon de recherche
          - voisin classé
      - FinSi**
        - éliminer l'impact du tampon de recherche
    - ⇒ **FinPour**
  - ↳ **FinTantque**
  - ⇒ **FinPour**
  - **FinSi**
  - ⇒ **FinPour**

Finalement, après la segmentation, un ensemble de régions  $R_i$  comportant  $N_i$  impacts est généré. Parmi ces régions, toutes ne correspondent pas forcément à un obstacle. Il est donc nécessaire d'effectuer une étape de reconnaissance pour ne retenir que les régions correspondant à des obstacles potentiels. Un exemple de segmentation est représenté sur la figure 2.23. Les régions extraites de la segmentation sont désignées par l'ensemble des rectangles noirs les englobant.



Figure 2.23 — Résultats de segmentation

### 2.6.1.2 La reconnaissance des obstacles

La reconnaissance consiste donc à extraire des régions issues de la segmentation les obstacles potentiels. Par exemple, il faudra extraire les deux obstacles de type voiture présents dans la scène représentée figure 2.23. Nous limiterons notre reconnaissance dans un premier temps à la recherche d'obstacles de type voiture ou camion qui sont évidemment les plus courants dans un contexte routier. Cette reconnaissance s'appuie sur le modèle 3D d'un véhicule vue de derrière qui est un simple rectangle. Il s'agira donc de comparer les dimensions de chaque région à celle du modèle ainsi défini afin de prendre une décision quant à l'assimilation d'une région à un obstacle.

Chaque région  $R_i$  issue de la segmentation comportant  $N_i$  impacts est paramétrée par un vecteur :

$$R_i = (X_{\min,i}, X_{\max,i}, Z_{\min,i}, Z_{\max,i}, Y_i)$$

où  $(X_{\min,i}, X_{\max,i})$  et  $(Z_{\min,i}, Z_{\max,i})$  sont respectivement les valeurs minimale et maximale des coordonnées des impacts suivant l'axe x et l'axe z du repère du capteur, et  $Y_i$  la distance de la région à notre capteur (figure 2.6).

Ces paramètres sont calculés de la façon suivante :

$$\begin{cases} X_{\min,i} = \min\{x_{a,i,j}, \forall j \in (1, \dots, N_i)\} \\ X_{\max,i} = \max\{x_{a,i,j}, \forall j \in (1, \dots, N_i)\} \\ Z_{\min,i} = \min\{z_{a,i,j}, \forall j \in (1, \dots, N_i)\} \\ Z_{\max,i} = \max\{z_{a,i,j}, \forall j \in (1, \dots, N_i)\} \\ Y_i = \frac{\sum_{j=1}^{N_i} y_{a,i,j}}{N_i} \end{cases}$$

Finalement, ces paramètres permettent le calcul de trois caractéristiques importantes pour la reconnaissance des obstacles :

- la largeur  $l_i$  :  $l_i = X_{\max,i} - X_{\min,i}$
- la hauteur  $h_i$  :  $h_i = Z_{\max,i} - Z_{\min,i}$
- la position du centre  $C_i(X_{obs,i}, Y_i, Z_{obs,i})$  :

$$\begin{cases} X_{obs,i} = (X_{\min,i} + X_{\max,i})/2 \\ Z_{obs,i} = (Z_{\min,i} + Z_{\max,i})/2 \end{cases}$$

Une région  $R_i$  est donc caractérisée par le vecteur suivant :

$$R'_i = (l_i, h_i, X_{obs,i}, Y_i, Z_{obs,i})$$

En comparant les composantes de ce vecteur aux dimensions des modèles de véhicules moyennant certaines tolérances, nous pourrions assimiler une région à un obstacle. Soit  $\Theta$  l'ensemble des  $N$  obstacles routiers. Un obstacle est représenté par le vecteur  $O_j = (L_j, H_j)$  où  $L_j$  et  $H_j$  sont



respectivement sa largeur et sa hauteur. Pour chaque région  $R_i$ , on peut écrire :

$$R_i \in \Theta \Leftrightarrow \left\{ \begin{array}{l} h_i = H_j \pm \sigma_{H,j} \\ l_i = L_j \pm \sigma_{L,j} \end{array} \right\} \forall j \in (1, \dots, N)$$

où  $\sigma_{H,j}$  et  $\sigma_{L,j}$  sont les tolérances sur les dimensions de l'obstacle  $O_j$  qui tiennent compte des variations de tailles possibles pour une même catégorie de véhicules. La figure 2.24 représente le résultat de cette reconnaissance : seules les deux régions caractérisant les voitures sont retenues en tant qu'obstacle.

Cependant cette méthode de reconnaissance connaît quelques problèmes dans différents cas illustrés




Figure 2.24 — Reconnaissance des obstacles de type voiture

sur la figure 2.25. Des erreurs de classification apparaissent. Par exemple, sur la figure 2.25, les détections sont dues à un mur dans l'image du haut et à un talus dans l'image du bas. Par l'analyse de la cinématique de l'obstacle, on pourrait sans doute conclure sur le caractère non dangereux de l'obstacle. De plus, dans le cadre d'une coopération avec un module de reconnaissance de la chaussée, ces détections sont facilement filtrées.

Cependant, pour éliminer ces erreurs de classification, sans coopération ni analyse du mouvement, on préfère rajouter des contraintes sur les normales aux différentes surfaces formant les régions (voir figure 2.26) :

$$\left\{ \begin{array}{l} \theta_{x,i} = \Theta_{x,k} \pm \sigma_{\Theta_{x,k}} \\ \theta_{y,i} = \Theta_{y,k} \pm \sigma_{\Theta_{y,k}} \\ \theta_{z,i} = \Theta_{z,k} \pm \sigma_{\Theta_{z,k}} \end{array} \right.$$

où  $\Theta_{x,k}$ ,  $\Theta_{y,k}$ ,  $\Theta_{z,k}$  représentent les angles de la normale à la surface d'un obstacle  $O_k$  ;  $\sigma_{\Theta_{x,k}}$ ,  $\sigma_{\Theta_{y,k}}$ ,  $\sigma_{\Theta_{z,k}}$  les tolérances sur ces angles, et  $\theta_{x,i}$ ,  $\theta_{y,i}$ ,  $\theta_{z,i}$  les angles de la normale à la surface formée par la région  $R_i$  détectée.



Figure 2.25 — Des fausses détections

Cette méthode s'appuie sur l'approximation, au sens des moindres carrés, de l'ensemble des points de mesures formant la région  $\{P_i = (x_{a,i,j}, y_{a,i,j}, z_{a,i,j}) \forall j \in (1 \dots N_i)\}$  par un plan d'équation :

$$y_{a,i} = f(x_{a,i}, z_{a,i}) = a_i x_{a,i} + b_i z_{a,i} + c_i$$




Figure 2.26 — Représentation d'une normale à un obstacle

On calcule les coefficients  $(a_i, b_i, c_i)$  en minimisant le critère :

$$\nabla = \sum_{j=0}^{N_i} (y_{a,i,j} - a_i x_{a,i,j} - b_i z_{a,i,j} - c_i)^2$$

On a donc :

$$\begin{pmatrix} a_i \\ b_i \\ c_i \end{pmatrix} = M_i^{-1} Q_i$$

avec :

$$M_i = \begin{pmatrix} \sum_{j=1}^{N_i} x_{a,i,j}^2 & \sum_{j=1}^{N_i} x_{a,i,j} z_{a,i,j} & \sum_{j=1}^{N_i} x_{a,i,j} \\ \sum_{j=1}^{N_i} x_{a,i,j} z_{a,i,j} & \sum_{j=1}^{N_i} z_{a,i,j}^2 & \sum_{j=1}^{N_i} z_{a,i,j} \\ \sum_{j=1}^{N_i} x_{a,i,j} & \sum_{j=1}^{N_i} z_{a,i,j} & \sum_{j=1}^{N_i} 1 \end{pmatrix} \text{ et } Q_i = \begin{pmatrix} \sum_{j=1}^{N_i} x_{a,i,j} y_{a,i,j} \\ \sum_{j=1}^{N_i} y_{a,i,j} z_{a,i,j} \\ \sum_{j=1}^{N_i} y_{a,i,j} \end{pmatrix}$$

On sait que le vecteur normal  $\vec{N}_i$  à une surface en  $P_i$ , point de coordonnées  $(x_{a,i}, f(x_{a,i}, z_{a,i}), z_{a,i})$  est donnée par :

$$\vec{N}_i = \frac{\partial OP_i}{\partial x} \wedge \frac{\partial OP_i}{\partial z} = \begin{pmatrix} 1 \\ f'_x(x_{a,i}, z_{a,i}) \\ 0 \end{pmatrix} \wedge \begin{pmatrix} 0 \\ f'_z(x_{a,i}, z_{a,i}) \\ 1 \end{pmatrix} = \begin{pmatrix} a_i \\ 1 \\ b_i \end{pmatrix}$$

où  $f'_x(x_{a,i}, z_{a,i})$  et  $f'_z(x_{a,i}, z_{a,i})$  sont respectivement les dérivées partielles en  $P_i$  de la fonction  $y_{a,i} = f(x_{a,i}, z_{a,i})$  selon  $x$  et  $z$ .

Finalement, on en déduit facilement que :

$$\begin{aligned}\theta_{x,i} &= \arccos\left(\frac{a_i}{\|\vec{N}_i\|}\right) (\pi) \\ \theta_{y,i} &= \arccos\left(\frac{1}{\|\vec{N}_i\|}\right) (\pi) \\ \theta_{z,i} &= \arccos\left(\frac{b_i}{\|\vec{N}_i\|}\right) (\pi)\end{aligned}$$

Nous avons ainsi détecté les obstacles et éliminé les fausses détections (voir figure 2.27), il est




Figure 2.27 — Résultats après ajout de contraintes sur les normales

maintenant nécessaire de mettre en oeuvre leur suivi afin d'en extraire des informations cinématiques importantes. Le suivi fera l'objet de la section 4.

## 2.6.2 Extraction des observations Radar Doppler à priorité Doppler

### 2.6.2.1 Extraction des mesures

L'objectif de cette étape est de déterminer la distance et la vitesse relatives des objets ou obstacles situés dans l'espace éclairé par le faisceau radar. Cette détection est réalisée à partir du signal  $s(t)$  défini par l'équation (2.1) p. 52. Les signaux  $I$  et  $Q$  représentent les parties réelles et imaginaires du signal  $s(t)$ . Ce signal est échantillonné en distance (indice  $p$ ) et en temps (indice  $n$ ) selon la relation suivante :

$$s[p, n] = \sum_i A_r(\vec{D}_i) u_g(p\delta D - D_i) \exp(j(4\pi \frac{v_i}{\lambda} n\delta t + \varphi_i))$$

L'indice  $i$  donne le numéro de l'objet renvoyant un écho, le vecteur distance  $\vec{D}_i$  dans l'amplitude du signal permet de tenir compte de l'angle antenne-objet c'est à dire de la position de la cible dans le champ d'émission du radar. L'échantillonnage en distance  $\delta D$  est lié à la largeur de l'impulsion

d'émission  $t_e$  par la relation :  $\delta D = \frac{\lambda f_0}{2} t_e$ , l'échantillonnage temporel  $\delta t$  est proportionnel à la période de répétitions des impulsions  $\delta t = t_r$ .

$p = 1, \dots, P$  et  $n = 0, \dots, N - 1$  où  $P$  représente le nombre de "portes distances" de largeur  $t_e$  et  $N$  le nombre de périodes de répétitions des impulsions  $t_r$ .

Le résultat de cette numérisation est donc un signal complexe de dimension  $P \times N$  dont la partie réelle est le signal  $I[p, n]$  et la partie imaginaire le signal  $Q[p, n]$ .

L'étape suivante consiste à calculer les  $P$  transformées de Fourier des signaux sur  $N$  échantillons numérisés selon l'équation suivante :

$$s[p, k] = \sum_i A_r(\vec{D}_i) u_g(p\delta D - D_i) TF(\exp(j(4\pi \frac{v_i}{\lambda} n\delta t + \varphi_i)))$$

$$s[p, k] = \sum_i A_r(\vec{D}_i) u_g(p\delta D - D_i) \exp(j\varphi_i) \Delta[k\delta v - v_i]$$

Par ce calcul on transforme l'axe des temps (indice  $n$ ) en axe des vitesses (indice  $k$ ) où la fonction  $\Delta[k\delta v - v_i]$  est définie par :

$$\Delta[k\delta v - v_i] = \frac{\sin(\pi N \frac{k\delta v - v_i}{v_{max}})}{\sin(\pi \frac{k\delta v - v_i}{v_{max}})}$$

avec :

$$v_{max} = \frac{\lambda}{2\delta t} \quad \delta v = \frac{v_{max}}{N}$$

$$k = -\frac{N}{2}, \dots, \frac{N}{2} - 1 \quad p = 1, \dots, P$$

Cette forme de représentation fréquentielle du signal traité provient de la numérisation qui oblige à borner à  $N$  échantillons l'observation du signal temporel.

L'échantillonnage en vitesse est inversement proportionnel à la période de répétition  $t_r$ . Par augmentation du nombre de points  $N$  dans le calcul de la transformée de Fourier on peut donc augmenter la résolution en vitesse au détriment de la durée totale d'analyse pour le même  $N$ . La valeur de  $N$  est donnée par l'utilisation du module de transformée de Fourier numérique rapide (ou FFT pour Fast

Fourier Transform) où le nombre d'échantillons à traiter prend une valeur en  $2^N$ .

Avant d'effectuer le calcul des FFT, un fenêtrage numérique est réalisée dans une fenêtre de Hamming. Ce filtrage permet d'éliminer la présence de lobes secondaires dans les signaux  $I$  et  $Q$  et ainsi d'éviter d'avoir plusieurs échos pour une même porte distance pour une même cible.

Par la suite, le calcul des  $P$  FFT est effectué. Une étape supplémentaire permet alors de rechercher la présence d'échos (obstacles) dans l'espace des transformées de Fourier. A l'issue du calcul des  $P$  transformées de Fourier, la présence d'un nouvel obstacle est considérée chaque fois que l'énergie dans l'espace de Fourier (tableau de dimension  $P \times N$ ) est supérieure à un seuil constant fixé expérimentalement. Pour chaque obstacle, il est nécessaire d'identifier sa vitesse relative par rapport au véhicule porteur du radar et la distance les séparant. L'indice correspondant aux lignes du tableau identifie l'indice de vitesse de l'obstacle, et l'indice colonne celui des distances. Dans notre cas, le nombre de portes distance utilisé est  $P = 5$  ou  $P = 10$  ce qui porte la distance maximale d'analyse à  $112.5 m$  ou  $225 m$ .

Un écho est alors défini par quatre paramètres :

- temps :  $n \times T_r, n \in [0, \dots, N - 1]$
- amplitude : énergie dans l'espace de Fourier
- Doppler :  $V_r = (\text{indice}_{\text{vitesse}} - \frac{N}{2}) * \delta v$
- distance :  $r = (\text{porte} - 1) \times \delta D + \frac{\delta D}{2}$

Finalement, le radar délivre donc, toutes les  $T_r = 8 ms$ , une mesure de temps, d'amplitude, de porte distance, d'indice vitesse. Une porte distance correspond à  $\delta D = 22.5 m$ , et un indice vitesse correspond à une vitesse de  $\delta v = 0.238 m/s$ . Une cible peut cependant générer plusieurs échos dans des portes voisines, avec des indices vitesse voisins, c'est pourquoi un prétraitement est nécessaire afin de regrouper les échos provenant d'une même cible. Une seconde phase permet le calcul des caractéristiques de la cible résultante afin d'aboutir à un vecteur de mesure  $Z^{rad} = \begin{pmatrix} r \\ \dot{r} \end{pmatrix}$  ainsi qu'à

sa covariance associée  $R^{rad} = \begin{pmatrix} \sigma_r^2 & 0 \\ 0 & \sigma_{\dot{r}}^2 \end{pmatrix}$

### 2.6.2.2 Regroupement des échos appartenant à la même cible

Les tests portent sur les indices de porte de distance ainsi que sur ceux des vitesses plutôt que sur les valeurs algébriques de ces deux grandeurs. L'indice vitesse du écho est noté  $IV_i$ , la porte  $Porte_i$ . On associe deux échos  $i$  et  $j$  si et seulement si :

$$|IV_i - IV_j| < \alpha$$

et

$$|Porte_i - Porte_j| < \beta$$

( $\alpha = 2$  et  $\beta = 2$  données par les caractéristiques du radar)

### 2.6.2.3 Calcul des caractéristiques de la cible résultante des $n$ échos associés

Soit  $n$  le nombre d'échos associés.

Mesure des caractéristiques de la cible :

$$Z^{rad} = \begin{pmatrix} r \\ \dot{r} \end{pmatrix}$$

La distance  $r$  d'une cible est donnée par :

$$r = (Porte_{moy} - 1) * LP + LP/2$$

avec

$$Porte_{moy} = \frac{\sum_{i=1}^n Porte_i * A_i}{\sum_{i=1}^n A_i}$$

où  $A_i$  est l'amplitude.

Pour chaque écho  $i$  on calcule la vitesse  $V_{r_i}$  correspondant à l'indice vitesse  $IV_i$ . La vitesse de la cible est alors :

$$\dot{r} = \frac{\sum_{i=1}^n \dot{r}_i * A_i}{\sum_{i=1}^n A_i}$$

Covariance sur la mesure :

$$R^{rad} = \begin{pmatrix} \sigma_r^2 & 0 \\ 0 & \sigma_{\dot{r}}^2 \end{pmatrix} \quad (2.2)$$

avec

$$\sigma_r^2 = \frac{\sum_{i=1}^n (Porte_i - Porte_{moy})^2 * A_i}{\sum_{i=1}^n A_i} * LP^2$$

et

$$\sigma_{\dot{r}}^2 = \frac{\sum_{i=1}^n (\dot{r}_i - \dot{r})^2 * A_i}{\sum_{i=1}^n A_i}$$

#### 2.6.2.4 Résultats

Les résultats pour l'extraction des mesures radar, présentés ici, sont issus de données acquises dans des conditions réelles de circulation. La figure 2.28 (resp. 2.29) représente les distances (resp. vitesses) brutes et les distances (resp. vitesses) filtrées. Le scénario proposé correspond à l'arrivée du véhicule porteur sur un obstacle ayant une vitesse relative négative. On remarque que différentes mesures brutes peuvent provenir d'échos issus de la même cible. En effet, quand une cible se rapproche de l'extrémité d'une porte, des échos peuvent apparaître dans la porte voisine. On peut faire la même remarque pour les vitesses. Le résultat du filtrage est représentée en rouge sur les figures. A des distances correspondant aux limites des portes, les mesures filtrées permettent d'avoir une information plus précise.



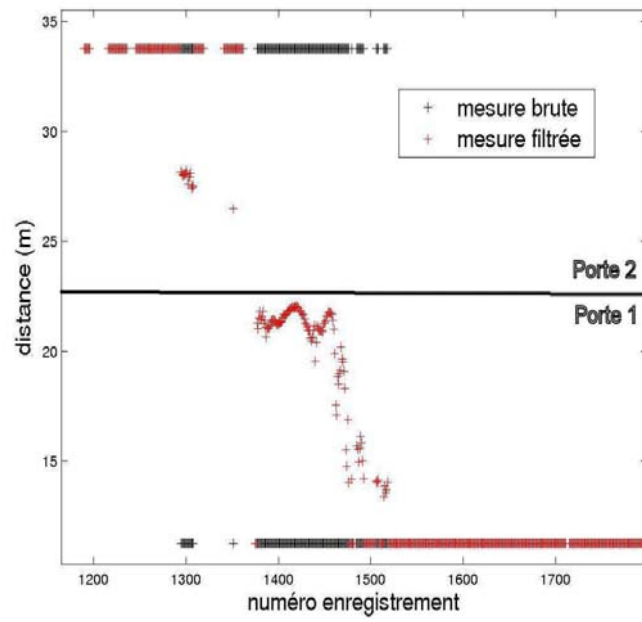


Figure 2.28 — Extraction de la distance radiale




Figure 2.29 — Extraction de la vitesse radiale

De plus, une campagne d'essais a été réalisée afin de savoir si une caractérisation des cibles étaient possible. L'amplitude des échos reçus ne permet pas d'avoir une caractérisation suffisante. Par exemple, on n'observe pas de différence d'amplitude entre une barrière de sécurité et une voiture, cette attribut ne sera donc pas exploité.

### 2.6.3 Extraction des observations infrarouge

La méthode décrite ci-dessous provient du travail effectué par SAGEM dans le cadre du projet PAROTO. Le lecteur pourra se référer à [46] pour de plus amples renseignements. Le principe de la détection repose sur une segmentation basée sur les propriétés de l'image infrarouge. Les positions 3D relatives au véhicule porteur sont calculées à partir de ces informations en se servant d'une hypothèse supplémentaire : la route devant le véhicule est considérée comme un plan. Sous l'hypothèse route plane, les relations géométriques biunivoques entre les points de la route et leurs projections à l'image sont utilisées pour estimer les positions relatives des obstacles. Le calibrage géométrique est donc d'une grande importance, puisqu'il détermine en partie la qualité de l'estimation des distances. Malheureusement, cette estimation reste fragile puisque tributaire des mouvements du véhicule, et notamment des changements d'assiette. Il est donc indispensable d'estimer le mouvement propre du porteur (ego-motion) à partir d'une analyse de mouvement dans l'image, et le compenser pour obtenir des positions relatives fiables. Cette technique est fortement apparentée à de la stabilisation de séquences d'images. L'analyse de mouvement est basée sur la poursuite de points caractéristiques. La segmentation et l'analyse de mouvement peuvent être réalisées en parallèle, et leurs résultats sont recoupés afin d'obtenir les informations les plus précises possibles, ainsi que l'illustre la figure 2.30. La figure 2.31 présente des résultats de détection.

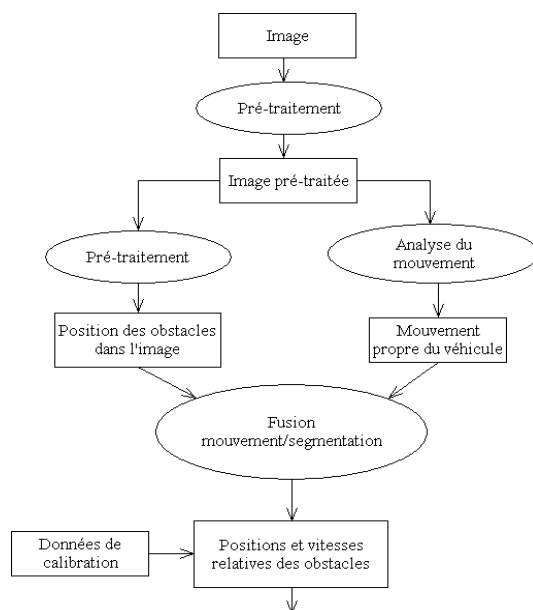


Figure 2.30 — Schéma général du module IR



Figure 2.31 — Détection de véhicules par IR : rectangles noirs

## 2.6.4 Conclusion

Cette partie a fourni une description des méthodes d'extraction de mesures d'obstacles respectives aux capteurs laser, radar et infrarouge. Le Lidar est capable de donner une représentation de la scène en trois dimensions. Après traitement de ces données, un algorithme délivre un ensemble de vecteurs

d'observations, dont les composantes sont la position et la taille de l'obstacle, pour chaque obstacle reconnu. Du côté du signal radar, les vecteurs d'observations sont composés d'une mesure de porte distance et d'une mesure d'indice vitesse. Une mesure de position latérale et longitudinale est donnée par la méthode de détection développée par SAGEM pour l'infrarouge. Pour chaque capteur les mesures sont regroupées dans des systèmes de plus haut niveau dont les sorties seront les caractérisations des obstacles en terme de position et vitesse relatives.



## Chapitre 3

# ESTIMATION DE PARAMETRES

Une représentation correcte de l'environnement routier à l'avant d'un véhicule repose, entre autre, sur la connaissance de l'état des différents usagers de la route. La détermination de ces différents états débute par l'estimation descriptive de ces états. On parlera de paramètres pour des quantités (scalaires / vecteurs) supposées temporellement invariantes. On cherchera par exemple à estimer la trajectoire des obstacles. Ces trajectoires seront définies par différents paramètres déterministes à évaluer. L'estimation des paramètres, détaillée dans la première partie, sera basée sur des méthodes de régression linéaire ou non linéaire suivant les observations (capteurs) et les modèles dynamiques utilisés. De plus, afin de caractériser d'une manière robuste la trajectoire du véhicule, la matrice d'information de Fisher (FIM) sera calculée.

Une deuxième partie détaillera le cas de l'estimation de la trajectoire d'un obstacle à partir des observations radar.

Les méthodes développées dans cette partie ne sont pour la plupart pas adaptées à une estimation temps réel des paramètres. Cependant, elles jugent de la capacité des modèles et des observations à estimer les paramètres déterminants pour une appréhension correcte de l'environnement routier.

### 3.1 Estimation de paramètres

Les méthodes statistiques d'estimation de paramètres sont basées sur la connaissance des composantes suivantes :

- l'ensemble où le(s) paramètre(s) à estimer,  $\theta$ , prennent valeurs : l'espace de paramètres,  $\Theta$  ;
- la loi de probabilité qui décrit l'effet du paramètre sur les observations :  $p(Z/\theta)$  (paramètres déterministes : approche non bayésienne) ;
- la loi de probabilité qui décrit l'effet du paramètre sur les observations :  $p(Z/\theta)$ , et la densité de probabilité à priori de  $\theta$  :  $p(\theta)$  (paramètres aléatoires : approche bayésienne) ;
- l'ensemble où les observations,  $Z$ , prennent valeurs : l'espace des observations  $Z$

Il existe donc deux modèles pour l'estimation de paramètres selon le caractère aléatoire de ceux ci. On parlera d'approche non bayésienne pour les paramètres déterministes. Dans ce cas, on utilise la densité de probabilité conditionnelle des mesures pour chaque valeur possible du paramètre : c'est la fonction de vraisemblance  $p(Z/\theta)$ . Quand les paramètres sont aléatoires, on parlera d'approche bayésienne. Pour ce deuxième modèle, on utilise la densité de probabilité à priori du paramètre à partir de laquelle on peut obtenir, par la formule de Bayes, la pdf a posteriori du paramètre :

$$p(\theta/Z) = \frac{p(Z/\theta)p(\theta)}{p(Z)} = \frac{1}{c} p(Z/\theta)p(\theta) \quad (3.1)$$

où  $c$  est une constante de normalisation qui ne dépend pas de  $\theta$ .

Le problème d'estimation de paramètres est décrit ci-dessous. Etant donné les mesures :

$$z(j) = h[j, \theta, w(j)]_{j=1, \dots, k} \quad (3.2)$$

effectuées en présence de bruit  $w(j)$ , on cherche une fonction des  $k$  observations

$$\hat{\theta}(k) \triangleq \hat{\theta}[k, Z^k] \quad (3.3)$$

où les observations sont définies d'une manière compacte par :

$$Z^k = \{z(j)\}_{j=1, \dots, k} \quad (3.4)$$

qui estime la valeur de  $\theta$ . La fonction 3.3 est appelée estimateur et sa valeur est l'estimé.

### 3.1.1 Les estimateurs

#### 3.1.1.1 Estimateurs à maximum de vraisemblance et à maximum a posteriori

Une méthode commune d'estimation de paramètres non aléatoires est la méthode du maximum de vraisemblance<sup>1</sup> qui maximise la fonction de vraisemblance :

$$\hat{\theta}^{ML} = \arg \max_{\theta} p(Z/\theta) \quad (3.5)$$

L'estimateur MLE<sup>2</sup> est la solution de l'équation :

$$\frac{dp(Z/\theta)}{d\theta} = 0 \quad (3.6)$$

L'estimateur correspondant pour un paramètre aléatoire est l'estimateur à maximum a posteriori<sup>3</sup> qui est issu de la maximalisation de la pdf à posteriori :

$$\hat{\theta}^{MAP} = \arg \max_{\theta} p(\theta/Z) = \arg \max_{\theta} [p(Z/\theta)p(\theta)] \quad (3.7)$$

#### 3.1.1.2 Estimation des moindres carrés et minimisation du carré des erreurs

Une autre méthode commune d'estimation de paramètres déterministes est la méthode des moindres carrés<sup>4</sup>. Etant donné des mesures (scalaire, linéaire ou non-linéaire) :

$$z(j) = h(j, \theta) + w(j) \quad (3.8)$$

l'estimateur des moindres carrés de  $\theta$  est :

$$\hat{\theta}^{LS}(k) = \arg \min_{\theta} \left\{ \sum_{j=1}^k [z(j) - h(j, \theta)]^2 \right\} \quad (3.9)$$

L'estimateur correspondant pour des paramètres aléatoires est l'estimateur qui minimise le carré des erreurs<sup>5</sup> :

---

<sup>1</sup>ML : Maximum Likelihood

<sup>2</sup>Maximum Likelihood Estimator

<sup>3</sup>MAP : Maximum A Posteriori

<sup>4</sup>LS : Least Square

<sup>5</sup>MMSE : Minimum Mean Square Error



$$\hat{\theta}^{MMSE}(Z) = \arg \min_{\hat{\theta}} E[(\hat{\theta} - \theta)^2 / Z] \quad (3.10)$$

La solution de cette équation est l'espérance conditionnelle de  $\theta$  :

$$\hat{\theta}^{MMSE}(Z) = E(\theta/Z) \triangleq \int_{-\infty}^{+\infty} \theta p(\theta/Z) d\theta \quad (3.11)$$

Tous ces estimateurs sont comparés dans [10]. Si, pour un ensemble de mesures données, les erreurs sont de moyennes nulles, gaussiennes et indépendantes alors l'estimé LS correspond à l'estimé ML. De même, l'estimé MAP d'une variable aléatoire gaussienne correspond à l'estimé MMSE. Pour évaluer la qualité des résultats, différentes méthodes sont détaillées dans la suite. On parlera d'estimateur non biaisé, de variance d'estimateur. De plus, la "limite d'information" sera appréhender par l'utilisation de la borne de Cramer-Rao et de l'information de Fisher.

### 3.1.1.3 Estimateur non-biaisé

On dit qu'un estimateur est non biaisé si l'erreur d'estimation est de moyenne nulle :

$$E(\tilde{\theta}) = 0 \quad (3.12)$$

où  $\tilde{\theta}$  est l'erreur d'estimation définie par :

$$\tilde{\theta} = \theta - \hat{\theta} \quad (3.13)$$

Un estimateur est non biaisé si 3.12 est vérifié pour tout  $k$ . On dit qu'il est asymptotiquement non biaisé si 3.12 est vérifié quand  $k$  tend vers l'infini.

### 3.1.1.4 Variance d'estimateur

Une deuxième caractéristique importante d'un estimateur est la variance de l'erreur d'estimation :

$$\text{var}(\hat{\theta}(Z)) \triangleq E[(\hat{\theta}(Z) - E(\hat{\theta}(Z)))^2] \quad (3.14)$$

Cette variance doit être aussi petite que possible, de façon à ce que l'estimé soit concentré autour de la vraie valeur du paramètre. La racine carré de la variance d'un estimateur<sup>6</sup> est l'écart type :

$$\sigma_{\theta} = \sqrt{\text{var}(\hat{\theta})} \quad (3.15)$$

L'écart type fournit une mesure de précision pour l'estimateur.

### 3.1.1.5 Borne de Cramer Rao et Matrice d'Information de Fisher

Dans l'étude de problèmes d'estimation paramétrique, une inégalité très utile établit qu'une borne inférieure pour la variance de l'erreur d'estimés non biaisés existe. Cette limite est connue sous le nom de Borne de Cramer Rao<sup>7</sup>.

#### Cas scalaire

Pour l'estimation d'un paramètre scalaire déterministe à partir d'un estimateur non biaisé, la variance est bornée par :

$$E[(\hat{\theta}(Z) - \theta_0)^2] \geq J^{-1} \quad (3.16)$$

où

$$J = -E \left[ \frac{\partial^2 \ln p(Z/\theta)}{\partial \theta^2} \right] \Bigg|_{\theta=\theta_0} = E \left\{ \left[ \frac{\partial \ln p(Z/\theta)}{\partial \theta} \right]^2 \right\} \Bigg|_{\theta=\theta_0} \quad (3.17)$$

est l'information de Fisher,  $p(Z/\theta)$  est la fonction de vraisemblance, et  $\theta_0$  est la vraie valeur de  $\theta$ .

#### Cas vectoriel

Pour un vecteur de paramètres déterministes, la matrice de covariance d'un estimateur non biaisé admet une borne minimale donnée par :

$$E[(\hat{\theta}(Z) - \theta_0)(\hat{\theta}(Z) - \theta_0)^t] \geq J^{-1} \quad (3.18)$$

---

<sup>6</sup>MSE : Mean Square Error

<sup>7</sup>CRLB : Cramer Rao Lower Bound

où la matrice d'information de Fisher<sup>8</sup> est :

$$J \triangleq -E [\nabla_{\theta} \nabla_{\theta}' \ln p(Z/\theta)]|_{\theta=\theta_0} = E [(\nabla_{\theta} \ln p(Z/\theta))(\nabla_{\theta} \ln p(Z/\theta))'|_{\theta=\theta_0}] \quad (3.19)$$

où

$$\nabla_{\theta} = \left[ \frac{\partial}{\partial \theta_1} \dots \frac{\partial}{\partial \theta_n} \right]^t \quad (3.20)$$

est l'opérateur de gradient et  $n$  la dimension du vecteur de paramètres. La matrice d'information de Fisher peut être vue comme une quantification du (maximum) d'information existante pour un paramètre à partir d'observations.

Les estimateurs qui vérifient avec égalité la borne de Cramer Rao sont dits efficaces. La preuve de l'existence de la borne de Cramer Rao est donnée dans [10].

### 3.1.2 Estimation linéaire et non linéaire

#### 3.1.2.1 Cas linéaire

##### Estimation des moindres carrées

###### Estimation batch

On souhaite estimer un vecteur  $\theta$  de paramètres, de dimension  $n_{\theta}$ , à partir d'un vecteur d'observations linéaires de dimension  $n_z$  :

$$z(i) = H(i)\theta + w(i), i = 1, \dots, k \quad (3.21)$$

en minimisant l'erreur quadratique suivante :

$$J(k) = \sum_{i=1}^k [z(i) - H(i)\theta]^t R(i)^{-1} [z(i) - H(i)\theta] = [z^k - H^k \theta]^t (R^k)^{-1} [z^k - H^k \theta] \quad (3.22)$$

où

$$z^k = \begin{pmatrix} z(1) \\ \vdots \\ z(k) \end{pmatrix} \quad (3.23)$$

---

<sup>8</sup>FIM : Fisher Information Matrix

est le vecteur "empilé" de mesures (de dimension  $kn_z \times 1$ ),

$$H^k = \begin{pmatrix} H(1) \\ \vdots \\ H(k) \end{pmatrix} \quad (3.24)$$

est la matrice "empilée" de mesure (de dimension  $kn_z \times n_\theta$ ),

$$w^k = \begin{pmatrix} w(1) \\ \vdots \\ w(k) \end{pmatrix} \quad (3.25)$$

est le vecteur "empilé" d'erreurs de mesures, et

$$R^k = \begin{pmatrix} R(1) & \dots & 0 \\ \vdots & \ddots & \vdots \\ 0 & \dots & R(k) \end{pmatrix} = \text{diag}[R(i)] \quad (3.26)$$

est une matrice diagonale par bloc définie positive de dimension  $kn_z \times kn_z$ .

L'estimateur des moindres carrés qui minimise 3.22 est obtenu en annulant le gradient par rapport à  $\theta$  :

$$\nabla_{\theta} J(k) = -2H^{kT} (R^k)^{-1} [z^k - H^k \theta] = 0 \quad (3.27)$$

Finalement, l'estimateur est donné par :

$$\hat{\theta}(k) = [H^{kT} (R^k)^{-1} H^k]^{-1} H^{kT} (R^k)^{-1} z^k \quad (3.28)$$

De plus, la matrice de covariance de l'estimateur des moindres carrés est donnée par [10] :

$$P(k) = [H^{kT} (R^k)^{-1} H^k]^{-1} \quad (3.29)$$

### Estimation itérative

L'estimateur des moindres carrés peut être écrit d'une manière itérative. Dans ce cas,  $k$  est considéré comme un temps discret. L'obtention de  $z(k+1)$  permet l'écriture des formes suivantes :

$$z^{k+1} = \begin{bmatrix} z^k \\ z(k+1) \end{bmatrix} \quad (3.30)$$

$$H^{k+1} = \begin{bmatrix} H^k \\ H(k+1) \end{bmatrix} \quad (3.31)$$

$$w^{k+1} = \begin{bmatrix} w^k \\ w(k+1) \end{bmatrix} \quad (3.32)$$

$$R^{k+1} = \begin{bmatrix} R^k & 0 \\ 0 & R(k+1) \end{bmatrix} \quad (3.33)$$

Les équations itératives sont données dans [10] :

$$\hat{\theta}(k+1) = \hat{\theta}(k) + W(k+1)[z(k+1) - H(k+1)\hat{\theta}(k)] \quad (3.34)$$

$$P(k+1) = P(k) - W(k+1)S(k+1)W(k+1)^t \quad (3.35)$$

où

$$W(k+1) \triangleq P(k)H(k+1)^t S(k+1)^{-1} \quad (3.36)$$

et

$$S(k+1) \triangleq H(k+1)P(k)H(k+1)^t + R(k+1) \quad (3.37)$$

Une initialisation est nécessaire puisque c'est une méthode itérative. Cela peut être réalisé en utilisant une technique dite "batch" sur un faible nombre de mesures ou en utilisant un estimé et une covariance associée à priori.

**Ajustement polynomial** On cherche à estimer les paramètres pour ajuster un polynôme de degré  $n$  à un ensemble d'observations. On considère que l'on observe, en présence de bruit, la distance  $r$  et la vitesse radiale  $\dot{r}$  d'un véhicule dont l'évolution radiale (position, vitesse) est modélisée par des polynômes (fonction du temps). Le modèle de régression est définie par :

$$\begin{aligned} r(t) &= \sum_{j=0}^n a_j \frac{t^j}{j!} \\ \dot{r}(t) &= \sum_{j=1}^n a_j \frac{t^{j-1}}{(j-1)!} \end{aligned} \quad (3.38)$$

où les paramètres à estimer sont les coefficients  $a_j$  du polynôme. Ils correspondent au dérivée d'ordre  $j$  de la position au temps initial ( $t = 0$ ). La méthode des moindres carrés est utilisée pour ajuster les

paramètres du polynôme de degré  $n$ . Le modèle de régression est définie par 3.38, on a :

$$Z^k = H^k \theta + w^k \quad (3.39)$$

où  $w^k$  est donné par 3.25 et  $H^k$  par 3.24 avec :

$$H(i) = \begin{pmatrix} 1 & t_i & \dots & \dots & \frac{t_i^n}{n!} \\ 0 & 1 & t_i & \dots & \frac{t_i^{n-1}}{(n-1)!} \end{pmatrix} \quad (3.40)$$

On donne le vecteur estimé de paramètres par[2] :

$$\hat{\theta} = (H^k H^k)^{-1} H^k Z^k \quad (3.41)$$

et sa matrice de covariance par :

$$P(k) = \left( H^k R^{k-1} H^k \right)^{-1} \quad (3.42)$$

où  $R^k$  est donnée par 3.26 avec :

$$R(i) = \begin{pmatrix} \sigma_r^2 & 0 \\ 0 & \sigma_f^2 \end{pmatrix} \forall i \in [1 \dots k] \quad (3.43)$$

On remarque ici que le vecteur de paramètres à estimer est indépendant des erreurs sur les observations. Finalement, après avoir déterminé les différents paramètres caractérisant la trajectoire de la cible, on peut prédire l'état de la cible pour un temps arbitraire. Si  $x(t)$ , au temps arbitraire  $t$ , est le vecteur d'état alors son estimé (prédiction) est :

$$\hat{x}(t/k) = F(t) \hat{\theta}(k) \quad (3.44)$$

où  $k$  est le nombre de mesures disponibles et  $F(t)$  est la matrice définie par :

$$F(t) = \begin{pmatrix} 1 & t & \dots & \frac{t^n}{n!} \\ 0 & 1 & \dots & \frac{t^{n-1}}{(n-1)!} \end{pmatrix} \quad (3.45)$$

La covariance correspondante est donnée par :

$$P(t/k) = F(t) P(k) F(t)' \quad (3.46)$$

### 3.1.2.2 Cas non linéaire

On présente ici l'utilisation de la technique des moindres carrés pour estimer un vecteur  $\theta$  de paramètres à partir de mesures non linéaires. Le vecteur "empilé" de mesures est donnée par :

$$z = z^k = h(\theta) + w^k \quad (3.47)$$

où  $h$  est une fonction non linéaire de  $\theta$  (dimension  $n_\theta$ ).

**Estimation itérative des moindres carrés : Méthode de Gauss-Newton** Cette méthode, basée sur le principe des moindres carrés, est une technique qui améliore séquentiellement l'estimé courant en utilisant les mesures disponibles. A partir de l'estimé  $\hat{\theta}_k$  à l'itération  $k$ , la mise à jour de l'estimé  $\hat{\theta}_{k+1}$  est donnée par :

$$\hat{\theta}_{k+1} = \hat{\theta}_k + (J_k^t R^k J_k)^{-1} J_k^t R^{k-1} [z^k - h(\hat{\theta}_k)] \quad (3.48)$$

où  $J_k = \left. \frac{\partial h}{\partial \theta} \right|_{\theta=\hat{\theta}_k}$  est la matrice jacobienne et  $R^k$  est la matrice de covariance définie par (3.26). La matrice jacobienne est donnée par :

$$J_k = \begin{pmatrix} \frac{\partial h(\theta(1))}{\partial \theta_1} & \dots & \frac{\partial h(\theta(1))}{\partial \theta_{n_\theta}} \\ \vdots & & \vdots \\ \frac{\partial h(\theta(i))}{\partial \theta_1} & \dots & \frac{\partial h(\theta(i))}{\partial \theta_{n_\theta}} \\ \vdots & & \vdots \\ \frac{\partial h(\theta(k))}{\partial \theta_1} & \dots & \frac{\partial h(\theta(k))}{\partial \theta_{n_\theta}} \end{pmatrix}_{\theta=\hat{\theta}_k} \quad (3.49)$$

L'erreur moyenne au sens des moindres carrés de l'estimé  $\hat{\theta}$  est :

$$E[(\hat{\theta}_k - \theta)(\hat{\theta}_k - \theta)^t] = (J^t R^{-1} J)^{-1} \quad (3.50)$$

### Estimation du maximum de vraisemblance : Méthode de Newton-Raphson

L'estimé  $\hat{\theta}^{MLE}$  est obtenu en maximisant la fonction de vraisemblance  $\Lambda(\theta)$  :

$$\Lambda(\theta) = \prod_{k=1}^n p(z(k)/\theta) \quad (3.51)$$

On a donc :

$$\hat{\theta}^{MLE} = \arg \max_{\theta} \Lambda(\theta) = \arg \min_{\theta} \{-\ln[\Lambda(\theta)]\} \stackrel{\Delta}{=} \arg \min \lambda(\theta) \quad (3.52)$$

Cette minimisation est effectuée en utilisant la méthode de Newton-Raphson qui repose sur une approximation linéaire à l'ordre 1 de la fonction de vraisemblance. L'estimé  $\hat{\theta}^k$ ; à l'instant  $k$ , est relié à l'estimé suivant  $\hat{\theta}^{k+1}$  par :

$$\hat{\theta}_{k+1}^{MLE} = \hat{\theta}_k^{MLE} - Hess_k^{-1} \nabla_{\theta} \lambda(\theta) \Big|_{\theta=\hat{\theta}_k^{MLE}} \quad (3.53)$$

où  $Hess_k$  est la matrice Hessienne à l'instant  $k$  définie par :

$$Hess_k = \begin{pmatrix} \frac{\partial^2 \lambda(\theta)}{\partial \theta_1^2} & \dots & \frac{\partial^2 \lambda(\theta)}{\partial \theta_1 \partial \theta_i} & \dots & \frac{\partial^2 \lambda(\theta)}{\partial \theta_1 \partial \theta_{n_{\theta}}} \\ \vdots & \ddots & & & \vdots \\ \frac{\partial^2 \lambda(\theta)}{\partial \theta_i \partial \theta_1} & & \frac{\partial^2 \lambda(\theta)}{\partial \theta_i^2} & & \frac{\partial^2 \lambda(\theta)}{\partial \theta_i \partial \theta_{n_{\theta}}} \\ \vdots & & & \ddots & \vdots \\ \frac{\partial^2 \lambda(\theta)}{\partial \theta_{n_{\theta}} \partial \theta_1} & \dots & \frac{\partial^2 \lambda(\theta)}{\partial \theta_{n_{\theta}} \partial \theta_i} & \dots & \frac{\partial^2 \lambda(\theta)}{\partial \theta_{n_{\theta}}^2} \end{pmatrix}_{\theta=\hat{\theta}_k^{MLE}} \quad (3.54)$$

## 3.2 Cas des observations radar

### 3.2.1 régression linéaire

On propose ici d'utiliser un scénario en virage. La construction de la route est visible dans 3.2.4. On suppose ici que le rayon de courbure est  $R = 850 \text{ m}$ , et la vitesse initiale  $v = 90 \text{ km/h}$ . La figure 3.1 montre ce scénario : coordonnées cartésiennes, distance réelle et mesures de porte distance, vitesse réelle et mesures d'indice vitesse. On se limitera ici à des polynômes d'ordre un, deux et trois.

Dans la suite, on présente un exemple de régression linéaire pour estimer les coefficients d'un :

- polynôme d'ordre 1 : modèle à vitesse constante
- polynôme d'ordre 2 : modèle à accélération constante
- polynôme d'ordre 3 : modèle à jerk constant

Les résultats présentés sont issus de l'observation de 150 mesures soit une durée d'analyse de 1.2 s. La durée d'analyse est telle que des changements de porte apparaissent. Les covariances sur les différents paramètres sont données par l'équation 3.42 et apparaissent sur la figure 3.2. La covariance






Figure 3.1 — Le scénario étudié

sur le paramètre  $r_0$  (voir figure 3.2) est indépendante du modèle utilisé. Pour le modèle à jerk constant, on parlera d'”over-fitting” : le paramètre caractérisant le jerk est insignifiant (covariance élevée). Les erreurs d'estimation au sens des moindres carrées<sup>9</sup>, sont données par :

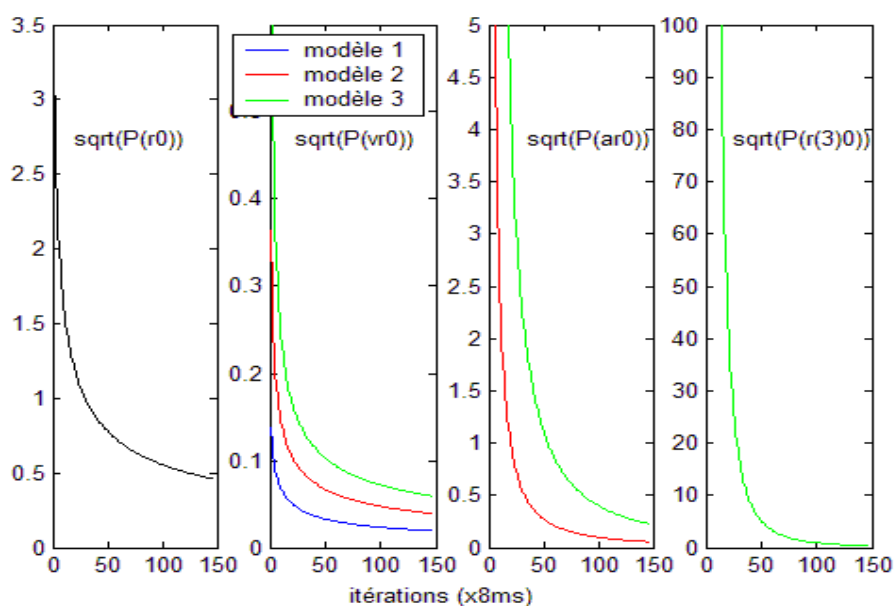


Figure 3.2 — Covariances sur les paramètres pour les différents modèles

<sup>9</sup>RMSE :Root Mean Square Error

$$rmse(t,k) = \sqrt{E\{[\hat{x}(t/k) - x(t,k)]^2\}} \quad (3.55)$$

où la valeur "estimée" est donnée par 3.44. La figure 3.3 présente ces erreurs. Les erreurs sur la distance sont équivalentes pour les différents modèles. Pour la distance et la vitesse, les modèles réagissent identiquement aux changements de portes (pic sur la figure 3.3). Cependant, la sensibilité à ces changements est moindre pour le modèle à vitesse constante. En effet, pour une telle durée d'analyse, la vitesse peut être considérée comme constante. Dans la suite, on choisira donc ce type de modèle pour l'estimation de la distance et de la vitesse radiale.




Figure 3.3 — RMSE sur la distance et vitesse radiale

### 3.2.2 Observabilité pour le pistage radar en coordonnées cartésiennes à partir de coordonnées polaires

L'étude de l'observabilité d'un système est un pré-requis nécessaire pour l'analyse du mouvement d'une cible. En particulier pour le problème caractéristique de l'estimation de positions et de vitesses données dans un repère cartésien à partir d'observations de distance et vitesse radiales, cette étude est primordiale. A ma connaissance, le pistage de cible à partir de mesures polaires seules (distance et vitesse) n'a pas fait l'objet de nombreuses communications au contraire du problème de suivi à partir de mesures d'angles seules. D'ailleurs, les deux principaux écrits sur ce sujet[94][88] s'inspirent des nombreux travaux en rapport avec l'analyse du mouvement par mesures d'angles seules dont une synthèse est visible dans[87]. Dans [94], une condition d'observabilité est établie à partir de la matrice d'information de Fisher et d'une transformation du repère cartésien dans un repère à coordonnées polaires modifiées<sup>10</sup>[1]. Cette condition stipule que si une cible se déplace à accélération constante alors l'observateur doit se déplacer à jerk non nul pour pouvoir observer la cible. De même, si l'observateur se déplace à accélération constante alors le critère d'observabilité ne sera pas atteint si l'obstacle ne se déplace pas à vitesse constante. Ce critère apparaît identique à celui stipulé pour l'analyse de trajectoire à partir de mesure d'angle seule. L'observabilité pourra donc être améliorée par les manoeuvres éventuelles de l'observateur. Dans [88], en supposant la condition précédente vérifiée, d'autres contributions sont présentées. Le calcul de la borne théorique de Cramer-Rao pour l'analyse des performances, à partir de mesures de distance et vitesse radiale, est présenté. Les auteurs montrent que cette borne, définissant la meilleure efficacité réalisable, dépend de la géométrie entre l'observateur et la cible, de la précision des mesures et de la fréquence d'échantillonnage. De plus, ils comparent trois algorithmes (MLE, EKF-AP, RPF) à cette borne et concluent que celui utilisant le filtre de Kalman étendu est le plus performant.

Dans notre cas, il est difficile de proposer à un conducteur d'adapter ses manoeuvres au contexte pour "arranger" l'observabilité du système. En effet, si un obstacle se déplace à vitesse constante, il sera difficile d'obliger le véhicule porteur à accélérer dans une quelconque direction, pour pouvoir accéder à l'état donné en coordonnées cartésiennes. On choisit donc d'utiliser les caractéristiques dynamiques du véhicule qui vont permettre de rendre observable le système. On suppose ici que l'on

---

<sup>10</sup>MPC : Modified Polar Coordinates

connaît les caractéristiques du véhicule à pister et la courbure de la route. Cette dernière condition pourra être par exemple vérifiée par l'utilisation d'une cartographie GPS précise et/ou d'un algorithme de reconnaissance de la route.

### 3.2.3 Dynamique du véhicule routier

D'une manière globale, l'expression "dynamique du véhicule routier" regroupe l'interaction entre les différents acteurs du système : conducteur-véhicule-infrastructure. Premièrement, le conducteur peut de différentes façons interférer avec le véhicule (figure 3.4) :




Figure 3.4 — Interaction conducteur-véhicule

Le véhicule fournit au conducteur différentes informations (figure 3.5) :

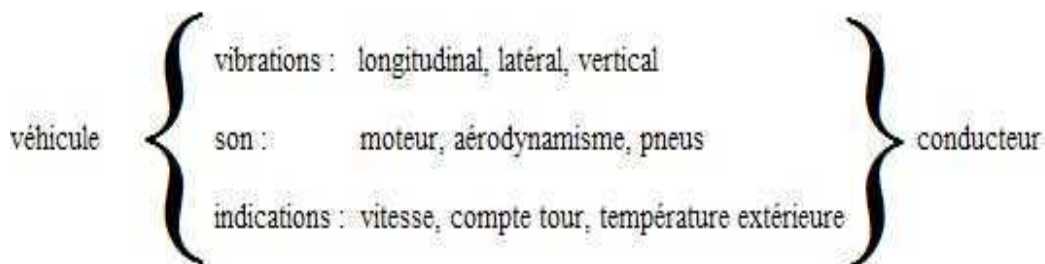


Figure 3.5 — Interaction véhicule-conducteur

L'environnement influence aussi le comportement du conducteur (figure 3.6) :




Figure 3.6 — Intéraction environnement-conducteur

Cependant, les réactions du conducteur sont véritablement complexes à modéliser. Des modèles "idéaux" sont parfois utilisés en simulation mais le transfert vers un conducteur que l'on qualifiera de "normal" reste difficile.

On insistera donc plutôt sur les propriétés dynamiques simples du véhicule (voiture) et en particulier, pour l'environnement, sur la modélisation de la route. En effet, la route (courbure, irrégularités, frottement, ...) est une source influente sur le véhicule.

### 3.2.3.1 Systèmes de coordonnées

Pour l'étude de la dynamique du véhicule plusieurs systèmes de coordonnées sont utilisés (figure 3.7). Le système d'axes  $(x_0, y_0, z_0)$  est fixé à la route. Le système lié au véhicule utilise un axe  $x_f$  qui pointe vers l'avant, un axe  $y_f$  dirigé vers la gauche et un axe  $z_f$  dirigé vers le haut. L'orientation de la roue est donnée par le vecteur unitaire  $e_y R$  dans la direction de l'axe des roues. Les vecteurs unitaires  $e_x, e_y$  dans la direction des forces latérale et longitudinale et le vecteur normale à la route  $e_n$  sont construits à partir de la "géométrie de contact". Dans la suite, on considère que le véhicule évolue dans un monde plan : on ne traitera donc pas l'influence du relief de la route ni la dynamique verticale du véhicule.

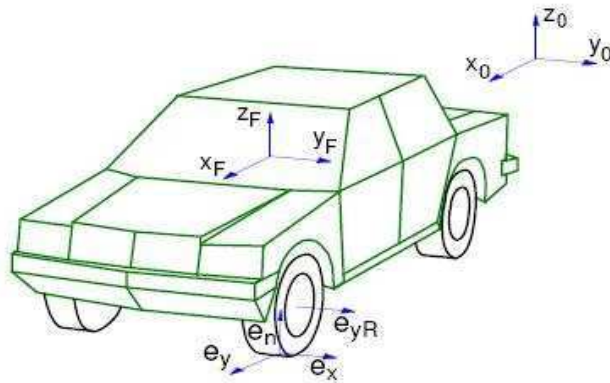


Figure 3.7 — Systèmes de coordonnées pour l'étude de la dynamique du véhicule

### 3.2.3.2 Dynamique longitudinale

**Modèle de véhicule simple** Le véhicule est considéré comme une masse rigide qui se déplace le long d'une route. Au niveau de chaque essieu, les forces au point de contact de la roue sur le sol sont données par une force normale et une force longitudinale (figure 3.8).




Figure 3.8 — Modèle simple de véhicule

Si les forces aérodynamiques sont négligées, alors les équations du mouvement du véhicule sont données par :

$$m\dot{v} = F_{x1} + F_{x2} \quad (3.56)$$

$$0 = F_{z1} + F_{z2} - mg \quad (3.57)$$

$$0 = F_{z1}a_1 - F_{z2}a_2 + (F_{x1} + F_{x2})h \quad (3.58)$$

où  $\dot{v}$  est l'accélération du véhicule,  $m$  sa masse,  $a1 + a2$  est la distance entre les deux essieux, et  $h$  est la hauteur du centre de gravité du véhicule.

On remarque qu'il y a seulement trois équations pour quatre forces inconnues. Cependant, si on insère 3.56 dans 3.58 alors on élimine deux forces inconnues et on a ainsi :

$$F_{z1} = mg \left[ \frac{a2}{a1 + a2} - \frac{h}{a1 + a2} \frac{\dot{v}}{g} \right] \quad (3.59)$$

et

$$F_{z2} = mg \left[ \frac{a1}{a1 + a2} + \frac{h}{a1 + a2} \frac{\dot{v}}{g} \right] \quad (3.60)$$

La détermination de ces deux forces, en supposant les forces aérodynamiques négligeables, permet le calcul de l'accélération maximale pour un véhicule donné.

**Accélération maximale** Les véhicules routiers ordinaires ne peuvent fournir que des forces de pression à la route. Si on applique  $F_{z1} \geq 0$  et  $F_{z2} \geq 0$  aux équations 3.59 et 3.60 alors on obtient une limite pour l'accélération  $\dot{v}$  qui dépend essentiellement des dimensions du véhicule :

$$-\frac{a1}{h} \leq \frac{\dot{v}}{g} \leq \frac{a2}{h} \quad (3.61)$$

L'accélération maximale est aussi limitée par les conditions de frottement :

$$|F_{x1}| \leq \mu F_{z1} \text{ et } |F_{x2}| \leq \mu F_{z2} \quad (3.62)$$

où le coefficient de frottement  $\mu$  est identique au niveau de l'essieu avant et arrière. Les conditions limites sont données par :

$$F_{x1} = \pm \mu F_{z1} \text{ et } F_{x2} = \pm \mu F_{z2} \quad (3.63)$$

On a donc en utilisant l'équation 3.56 :

$$\dot{v}_{max} = \pm \mu \quad (3.64)$$

Selon les dimensions du véhicule et le coefficient de frottement l'accélération ou la décélération maximale est donnée soit par 3.61 ou par 3.64.

**Traction/Propulsion et freinage** Si on suppose que l'on est aux conditions limites, i.e.  $F_{x1} = 0$  et  $F_{x2} = \mu F_{z2}$  pour une propulsion et  $F_{x1} = \mu F_{z1}$  et  $F_{x2} = 0$  pour une traction, alors en utilisant 3.56 on

montre facilement que :

$$\frac{\dot{v}_{prop}}{g} = \frac{\mu}{1 - \mu \frac{h}{a_1 + a_2}} \frac{a_2}{a_1 + a_2} \quad (3.65)$$

et

$$\frac{\dot{v}_{tract}}{g} = \frac{\mu}{1 + \mu \frac{h}{a_1 + a_2}} \frac{a_2}{a_1 + a_2} \quad (3.66)$$

Pour une voiture "normale" le paramètre  $\frac{a_2}{a_1 + a_2}$  est borné [86]. Pour un véhicule à propulsion et à traction on a couramment ( $\mu = 1$  et  $h = 0.55$ ) :

$$0.4 \leq a_2/a_1 + a_2 \leq 0.5 \text{ donc } 0.64 \leq \dot{v}/g \leq 0.77 \text{ pour une propulsion.}$$

$$0.55 \leq a_2/a_1 + a_2 \leq 0.6 \text{ donc } 0.45 \leq \dot{v}/g \leq 0.49 \text{ pour une traction.}$$

Les véhicules à propulsion peuvent donc accélérer plus vite que ceux disposant d'une traction.

On peut procéder de la même façon pour le freinage et montrer que, pour  $0.4 \leq a_2/a_1 + a_2 \leq 0.6$ , on a  $-0.77 \leq \dot{v}/g \leq -0.51$  pour un freinage distribué sur l'essieu avant, et  $-0.49 \leq \dot{v}/g \leq -0.33$  pour un freinage distribué sur l'essieu arrière. Ces différentes bornes pourront être utilisées afin d'améliorer l'estimation de l'état de la cible. Par exemple, si on utilise un modèle à vitesse constante, la valeur de la covariance sur le bruit (accélération longitudinale dans ce cas) sera fixée par ces bornes.

### 3.2.3.3 Dynamique latérale

**Géométrie d'Ackermann** Dans une courbe à très basse vitesse, les efforts latéraux sur les pneus sont négligeables, et le roulis quasiment nul. La condition de non-glissement des roues implique que les roues directrices doivent être braquées d'un angle différent selon qu'il s'agit de la roue intérieure ou de la roue extérieure. Ackermann suppose, pour simplifier, que le centre de courbure est situé au niveau de l'axe de l'essieu arrière (figure 3.9).

La connaissance de l'empattement  $a$  et de l'angle  $\delta_2$  fixe le rayon de courbure :

$$R = \frac{a}{\tan \delta_2} \quad (3.67)$$






Figure 3.9 — Géométrie de direction d'Ackermann

Pour l'autre roue on a de la même façon :

$$R = \frac{a}{\tan \delta_1} - b \quad (3.68)$$

L'angle  $\beta$  entre le vecteur vitesse du véhicule  $v$  et l'axe longitudinal du véhicule est l'angle latéral de glissement ou l'angle latéral de dérive.

**Modèle simple** Les forces des pneus appartenant au même essieu sont combinées en une force résultante. Pour des faibles glissements latéraux, la force latérale peut être approximée par une approche linéaire :

$$F_y = c_s s_y \quad (3.69)$$

où  $c_s$  est une constante qui dépend de la pression du pneu et  $s_y$  le glissement latéral. Le mouvement du véhicule, figure 3.10, dans le plan  $(x_0, y_0)$  est seulement influencé par les forces latérales suivantes [86] :

$$F_{y1} = c_s 1 s_y A_1; F_{y2} = c_s 2 s_y A_2 \quad (3.70)$$

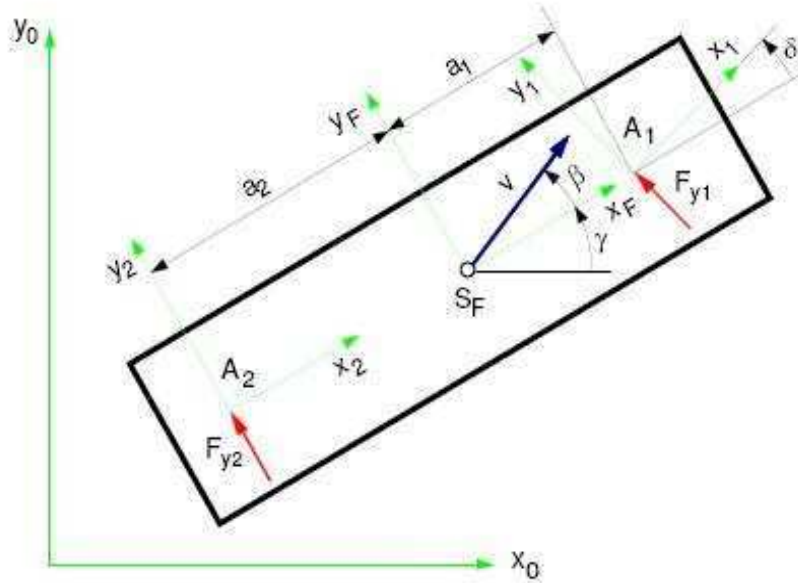


Figure 3.10 — Modèle simple de véhicule (latéral)

Dans [86], l'auteur montre que pour un véhicule, en manoeuvre de virage, à vitesse  $v$  constante on a le système linéaire suivant :

$$\underbrace{\begin{pmatrix} \dot{\beta} \\ \dot{\omega} \end{pmatrix}}_x = \underbrace{\begin{pmatrix} -\frac{c_{s1}+c_{s2}}{mv} & \frac{a_2c_{s2}-a_1c_{s1}}{mv^2} - 1 \\ \frac{a_2c_{s2}-a_1c_{s1}}{\Theta} & -\frac{a_1^2c_{s1}+a_2^2c_{s2}}{\Theta v} \end{pmatrix}}_A \underbrace{\begin{pmatrix} \beta \\ \omega \end{pmatrix}}_x + \underbrace{\begin{pmatrix} \frac{c_{s1}}{mv} \\ \frac{a_1c_{s1}}{\Theta} \end{pmatrix}}_B \underbrace{\delta}_u \quad (3.71)$$

où  $\omega = \dot{\gamma}$  est la vitesse angulaire du cap,  $a_1, a_2, c_{s1}, c_{s2}, \Theta$  sont des constantes données dans [86].

L'équation dynamique d'état du système à temps continu est donc donnée par :

$$\dot{x}(t) = Ax(t) + Bu(t) \quad (3.72)$$

dont la solution est de la forme :

$$x(t) = F(t, t_0)x(t_0) + \int_{t_0}^t F(t, \tau)Bu(\tau)d\tau \quad (3.73)$$

où  $x(t_0)$  est l'état initial et  $F(t, t_0)$  est la matrice de transition de l'état de l'instant  $t_0$  à l'instant  $t$ . Pour un système, de période d'échantillonnage fixe, on montre facilement que, pour  $t_0 = 0$  :

$$F(t) \hat{=} F(t, t_0) = e^{At} \quad (3.74)$$

Pour évaluer la matrice de transition, on utilise un développement en série :

$$e^{At} = \sum_{k=0}^{\infty} \frac{(At)^k}{k!} = I + At + \frac{1}{2}At^2 + \dots \quad (3.75)$$

On se limitera, dans de nombreux cas, au développement à l'ordre 2. De plus, une étude simple à l'équilibre permet d'avoir une solution dite stable définie ci-dessous :

$$\begin{aligned} \beta_{st} &= \frac{a_2 - mv \frac{a_1}{c_{s2}(a_1 + a_2)}}{a_1 + a_2 + mv \frac{a_2 c_{s2} - a_1 c_{s1}}{c_{s1} c_{s2} (a_1 + a_2)}} \delta_0 \\ \omega_{st} &= \frac{v}{a_1 + a_2 + mv \frac{a_2 c_{s2} - a_1 c_{s1}}{c_{s1} c_{s2} (a_1 + a_2)}} \delta_0 \end{aligned} \quad (3.76)$$

où  $\delta_0$  est l'angle de braquage des roues donné en fonction du rayon de courbure  $R$  de la route et des caractéristiques du véhicule :

$$\delta_0 = \frac{a_1 + a_2}{R} + m \frac{v}{R} \frac{a_2 c_{s2} - a_1 c_{s1}}{c_{s1} c_{s2} (a_1 + a_2)} \quad (3.77)$$

A partir de la connaissance de l'état initial et de la courbure de la route, la vitesse supposée connue, on pourra donc estimer l'angle de dérive latéral  $\beta$  et la vitesse angulaire du cap  $\omega$  du véhicule. L'état initial pourra être déterminé (estimé) par régression linéaire à partir des solutions stables.

### 3.2.4 Modélisation de la route

La route est le plus souvent modélisée par des lignes droites, des arcs et des clothoïdes [28]. Les clothoïdes sont des courbes dont la courbure évolue linéairement en fonction de la distance  $x$  le long de celle-ci. La fonction définie ci-dessous pour la courbure est efficace dans la majorité des cas [34] :

$$c(x) = c_0 + c_1 x \quad (3.78)$$

La construction de la route suit les directives données dans [34]. Pour une route limitée à 50 km/h, le rayon de courbure minimum est de 140 m, et pour une route limitée à 90 km/h il est de 550 m. Les paramètres de la clothoïde sont donnés par  $c_1 = \frac{k}{v^3}$  où  $k = 0.45$  ( $m/s^3$ ) est le jerk maximum et  $v$  la vitesse. La figure 3.11 représente différentes routes construites à partir des indications précédentes.




Figure 3.11 — Modèles de route

### 3.2.5 Estimation non linéaire

On a vu précédemment que l'observabilité du système est donnée par une condition qu'il sera difficile de respecter dans un contexte routier. On choisit donc d'inclure une autre information, vitesse du cap  $\omega$ , estimée par régression linéaire à partir de la connaissance de la courbure de la route et des caractéristiques du véhicule (voir 3.2.3.3). La connaissance de la vitesse angulaire du cap permet de définir le modèle d'évolution suivant [69] :

$$X_{k+1} = F(\omega)X_k + w_k \quad (3.79)$$

où

$$X_k = (x_k \dot{x}_k y_k \dot{y}_k)^t \quad (3.80)$$

$$F(\omega) = \begin{pmatrix} 1 & \frac{\sin \omega \Delta t}{\omega} & 0 & -\frac{1 - \cos \omega \Delta t}{\omega} \\ 0 & \cos \omega \Delta t & 0 & -\sin \omega \Delta t \\ 0 & \frac{1 - \cos \omega \Delta t}{\omega} & 1 & \frac{\sin \omega \Delta t}{\omega} \\ 0 & \sin \omega \Delta t & 0 & \cos \omega \Delta t \end{pmatrix} \quad (3.81)$$

et

$$\text{cov}(w_k) = \begin{pmatrix} \frac{2(\omega\Delta t - \sin \omega\Delta t)}{\omega^3} & \frac{1 - \cos \omega\Delta t}{\omega^2} & 0 & \frac{\omega\Delta t - \sin \omega\Delta t}{\omega} \\ \frac{1 - \cos \omega\Delta t}{\omega^2} & \Delta t & -\frac{\omega\Delta t - \sin \omega\Delta t}{\omega^2} & 0 \\ 0 & -\frac{\omega\Delta t - \sin \omega\Delta t}{\omega^2} & \frac{2(\omega\Delta t - \sin \omega\Delta t)}{\omega^3} & \frac{1 - \cos \omega\Delta t}{\omega^2} \\ \frac{\omega\Delta t - \sin \omega\Delta t}{\omega^2} & 0 & \frac{1 - \cos \omega\Delta t}{\omega^2} & \Delta t \end{pmatrix} \quad (3.82)$$

Dans notre cas, on aura  $\omega\Delta t \approx 0$ . On pourra donc approximer  $F(\omega)$  par :

$$F(\omega) \approx \begin{pmatrix} 1 & \Delta t & 0 & -\frac{\omega\Delta t}{2} \\ 0 & 1 - \frac{(\omega\Delta t)}{2} & 0 & -\omega\Delta t \\ 0 & \frac{\omega\Delta t}{2} & 1 & \Delta t \\ 0 & \omega\Delta t & 0 & 1 - \frac{(\omega\Delta t)}{2} \end{pmatrix} \quad (3.83)$$

### 3.2.5.1 Définition du problème

La cible se déplace le long d'une trajectoire définie par la courbure de la route. Dans le scénario étudié, le rayon de courbure sera fixé à  $R = 850 \text{ m}$  et la vitesse initiale à  $v = 25 \text{ m/s}$ . On construit la trajectoire en utilisant la définition des clothoïdes donnée dans 3.2.4. Le scénario est identique à celui défini dans 3.2.1. Le problème est d'estimer l'état cinématique de la cible (position, vitesse, cap) à partir d'observations de position, vitesse radiales et vitesse angulaire du cap. L'état dynamique de la cible est complètement défini si on utilise les composantes suivantes :

$$X_k = [x_k \dot{x}_k y_k \dot{y}_k]^t \quad (3.84)$$

où  $x_k$  et  $y_k$  sont les coordonnées cartésiennes de la cible au temps  $k$ , et  $\dot{x}_k$ ,  $\dot{y}_k$  sont leurs vitesses respectives. Le vecteur de mesures à l'instant  $k$  est définie par :

$$z_k = \begin{pmatrix} r_k \\ \dot{r}_k \\ \omega_k \end{pmatrix} \quad (3.85)$$

où  $r_k$ ,  $\dot{r}_k$  et  $\omega_k$  sont les observations de distance radiale, de vitesse radiale et de vitesse angulaire de cap. L'équation de mesure est donnée par :

$$z_k = \begin{pmatrix} r_k \\ \dot{r}_k \\ \omega_k \end{pmatrix} = \begin{pmatrix} h_r(X_k) \\ h_{\dot{r}}(X_k) \\ h_{\omega}(X_k) \end{pmatrix} + w_k = h(X_k) + w_k \quad (3.86)$$

où

$$h_r(X_k) = \sqrt{x_k^2 + y_k^2} \quad (3.87)$$

$$h_{\dot{r}}(X_k) = \frac{x_k \dot{x}_k + y_k \dot{y}_k}{\sqrt{x_k^2 + y_k^2}} \quad (3.88)$$

$$h_{\omega}(X_k) = \frac{x_k \dot{y}_k - \dot{x}_k y_k}{x_k^2 + y_k^2} \quad (3.89)$$

Le bruit  $w_k$  est considéré gaussien de moyenne nulle et décorrélé :  $w_k \sim N(0; R)$ . Sa matrice de covariance est définie par :

$$R = \begin{pmatrix} \sigma_r^2 & 0 & 0 \\ 0 & \sigma_{\dot{r}}^2 & 0 \\ 0 & 0 & \sigma_{\omega}^2 \end{pmatrix} \quad (3.90)$$

On considère le modèle d'état définie en 3.79. On a donc :

$$\begin{cases} x(t) = x(t_0) + \dot{x}(t_0)(t - t_0) - \dot{y}(t_0)\omega(t_0)\frac{(t-t_0)^2}{2} \\ \dot{x}(t) = \dot{x}(t_0) \left(1 - \frac{\omega(t_0)(t-t_0)^2}{2}\right) - \dot{y}(t_0)\omega(t_0)(t - t_0) \\ y(t) = y(t_0) + \dot{y}(t_0)(t - t_0) + \dot{x}(t_0)\omega(t_0)\frac{(t-t_0)^2}{2} \\ \dot{y}(t) = \dot{y}(t_0) \left(1 - \frac{\omega(t_0)(t-t_0)^2}{2}\right) + \dot{x}(t_0)\omega(t_0)(t - t_0) \end{cases} \quad (3.91)$$

Le problème est alors d'estimer les paramètres déterministes de la trajectoire, i.e. le vecteur de paramètres  $\theta$  :

$$\theta = \begin{pmatrix} x_0 \\ \dot{x}_0 \\ y_0 \\ \dot{y}_0 \\ \omega_0 \end{pmatrix} \quad (3.92)$$

pour  $t_0 = 0$ .

### 3.2.5.2 Borne de Cramer Rao

La borne de Cramer Rao d'un estimateur non biaisé  $\hat{\theta}$  du vecteur de paramètre est donnée par l'inverse de la matrice d'information de Fisher(FIM) :

$$E[(\hat{\theta} - \theta)(\hat{\theta} - \theta)^t] \geq J_k^{-1} \quad (3.93)$$

où la FIM est :

$$J_k = E\{[\nabla\lambda(\theta)][\nabla\lambda(\theta)]^t\} \quad (3.94)$$

$\lambda(\theta)$  est l'opposé du logarithme de la fonction de vraisemblance, i.e. :

$$\lambda(\theta) = -\log p(z^k/\theta) \quad (3.95)$$

et  $\nabla$  est l'opérateur gradient par rapport au vecteur de paramètre  $\theta$ . Le terme  $z^k$  est définie par l'équation 3.23. Si on suppose l'indépendance sur les bruits de mesures alors la fonction de vraisemblance est exprimée par le produit suivant :

$$p(z^k/\theta) = \prod_{i=0}^k p(z_i/\theta) \quad (3.96)$$

De plus comme les bruits sur les mesures sont gaussiens et de moyenne nulle alors :

$$p(z_i/\theta) = \frac{1}{2\pi\sqrt{|R|}} \exp[-\frac{1}{2}(z_i - h(i, \theta))^t R^{-1}(z_i - h(i, \theta))] \quad (3.97)$$

A partir des équations 3.95 et 3.97 on montre que la fonction logarithme de la vraisemblance peut être exprimée par :

$$\lambda(\theta) = \sum_{i=0}^k \lambda_i \quad (3.98)$$

où  $\lambda_i = \frac{1}{2}[z_i - h(i, \theta)]^t R^{-1}[z_i - h(i, \theta)]$ . Finalement, par le calcul du gradient de  $\lambda(\theta)$ , on montre que :

$$J_k = \sum_{i=0}^k [\nabla(h(i, \theta))^t] R^{-1} [\nabla(h(i, \theta))]^t \quad (3.99)$$

Les bornes de Cramer Rao sont données par les éléments diagonaux de l'inverse de la matrice de Fisher, i.e :

$$CRLB(\theta_j) = J_{jj}^{-1} \quad (3.100)$$

A partir du scénario défini dans 3.2.5.1, on calcule les bornes par la méthode définie ci-dessus. Les variances sur la distance et la vitesse sont fixées à partir des résultats obtenus par régression linéaire : on choisit  $\sigma_r = 1 \text{ m}$  et  $\sigma_{\dot{r}} = 0.1$ . On analyse ensuite l'effet de la courbure de la route sur les bornes des différentes composantes du vecteur. On utilise ici la connaissance de la route et de la distance radiale de la cible, en initialisant la matrice de Fisher. Par exemple, pour sa valeur sur  $x$ , on suppose que la cible appartient à la route. On pourra définir  $\sigma_x$  en utilisant l'approximation faite dans (4.79) pour une largeur de route donnée (distribution beta  $\approx$  distribution gaussienne). Les valeurs de la borne sont représentées sur les figures 3.12 3.13 pour des courbures de route différentes. Au vue des bornes, on remarque que plus la courbure de la route est forte, alors plus l'estimation pourra être performante, en particulier sur l'estimation de  $x$  et  $\dot{x}$ . Pour  $y$  et  $\dot{y}$ , l'estimabilité est quasiment indépendante de la courbure de la route.




Figure 3.12 — Bornes de Cramer Rao pour  $x$  et  $\dot{x}$






Figure 3.13 — Bornes de Cramer Rao pour  $y$  et  $\dot{y}$

### 3.2.5.3 Estimation des paramètres de la trajectoire en virage

On suppose ici que les observations sont d'une part la distance radiale et la vitesse radiale qui pourront être données par la régression linéaire effectuée en 3.2.1. D'autre part, selon la courbure de la route, on pourra estimer la vitesse angulaire du cap également par régression et considérer que cette estimation devient une observation. A partir du scénario précédent, on montre en utilisant la méthode de Gauss-Newton, présentée en 3.1.2.2, la capacité du système à estimer les caractéristiques cinématiques du véhicule dans un repère cartésien. On utilise le modèle définie en 3.91.

La méthode utilisée pour la régression non linéaire nécessite une initialisation du vecteur de paramètres.

**Initialisation de  $x_0$**  L'estimation de  $x$  est dépendante de l'erreur sur l'initialisation de  $x_0$ . Les modèles ne permettent pas la convergence de  $x$  vers la vraie valeur. Cependant, ils permettent d'avoir une représentation de la trajectoire du véhicule. Sur les figures suivantes, la vraie trajectoire du véhicule sera représentée en rouge et les bords gauche et droit en noir pour une largeur de route de  $5m$ . La figure 3.14 montre les trajectoires du véhicule pour différentes initialisations de  $x_0$  ( $x_0 - 2 \leq x_{0_{min}} \leq x_0 + 2 : x_0$  étant la vraie position). Au vue de ces figures, on pourra selon la confiance

que l'on a sur l'initialisation de  $x_0$ , qui peut être donnée par la largeur de la route, définir un intervalle de confiance sur  $x$  et  $y$  illustré par les différentes trajectoires possibles de la cible.




Figure 3.14 — Représentation des trajectoires estimées selon l'initialisation de  $x_0$

**Initialisation de  $y_0$**  L'estimation de  $x$  est aussi dépendante de l'erreur d'initialisation de  $y$ , même si une erreur d'initialisation d'une dizaine de mètres sur  $y$  n'engendre qu'une erreur d'une vingtaine de centimètres sur  $x$ . La figure 3.15 correspond à l'estimation de  $x$  et  $y$  pour différentes valeurs d'initialisation de  $y_0$  ( $y_0 - 10 \leq y_{0_{init}} \leq y_0 + 10$ ).

**Initialisation sur  $\dot{x}_0$  et  $\dot{y}_0$**  La figure 3.16 dévoile les différentes trajectoires estimées à partir des deux modèles pour différentes valeurs d'initialisation de  $\dot{x}_0$ . On constate que le modèle est largement plus sensible à  $\dot{x}_0$  ( $\dot{x}_0 - 2 \leq \dot{x}_{0_{init}} \leq \dot{x}_0 + 2$ ). La figure 3.17 montre la moindre sensibilité sur l'erreur d'initialisation sur  $\dot{y}_0$  ( $\dot{y}_0 - 10 \leq \dot{y}_{0_{init}} \leq \dot{y}_0 + 10$ ).




Figure 3.15 — Représentation des trajectoires estimées selon l'initialisation de  $y_0$




Figure 3.16 — Représentation des trajectoires estimées selon l'initialisation de  $\dot{x}_0$




Figure 3.17 — Représentation des trajectoires selon l'initialisation de  $\dot{y}_0$

### 3.3 Conclusion

L'estimation des paramètres de la trajectoire par régression linéaire ou non linéaire selon la linéarité des mesures a été développée dans ce chapitre. La régression est basée sur l'estimation au sens des moindres carrés. Dans la cas où l'on cherche à estimer la trajectoire radiale (distance, vitesse), la régression linéaire est satisfaisante pour les observations radar. Cependant, pour une plus nette compréhension de la scène, il est nécessaire de connaître les caractéristiques cinématiques (position, vitesse) dans un repère cartésien. L'étude de l'observabilité de l'état dans un repère cartésien à partir de mesures de distance et vitesse radiales montre que pour estimer la trajectoire d'un véhicule se déplaçant à vitesse constante, il est nécessaire que l'observateur effectue un mouvement à accélération constante. Cette condition, dans un contexte d'assistance au conducteur, ne pourra pas être respectée. On choisit donc plutôt d'utiliser un modèle dynamique simple d'un véhicule routier. En effet, à partir de ce modèle et par la connaissance de la vitesse du véhicule et de la courbure de la route (cartographie GPS précise par exemple), on estime par régression linéaire la vitesse angulaire du cap. A partir de cette nouvelle estimation, le calcul de la borne de Cramer Rao nous renseigne sur l'estimabilité des composantes déterministes de la trajectoire selon la courbure de la route. La précision des estimations est fortement liée à l'initialisation de la vitesse  $\dot{x}_0$ . De plus, le

modèle dynamique du véhicule est dépendant de paramètres qui diffèrent selon les véhicules routiers. Il sera donc difficile de fixer ces paramètres. Cependant, la construction des différentes trajectoires selon les différentes initialisations permet de définir des intervalles de confiance pour la position dans un repère cartésien.

L'estimation de paramètres a permis de mettre en concordance les propriétés physiques de la cible et des capteurs (en particulier du radar) avec les paramètres d'un modèle mathématique.

Néanmoins, toutes ces méthodes sont généreuses en temps de calcul puisqu'elles nécessitent la connaissance de toutes les mesures. On pourra, cependant, fixer le nombre de mesures à traiter.

## Chapitre 4

# LE SUIVI DES OBSTACLES

Le rôle du pistage de cible est avant tout d'assurer la cohérence temporelle des observations afin d'éviter les fausses alarmes et de filtrer l'état. La structure haut niveau d'un tel système est donnée figure 4.1. Les capteurs délivrent des signaux qui sont collectés par un module de traitement du signal délivrant des mesures au traitement des données. Les pistes sont des éléments du sous système de traitement des données dont le rôle est de former et de maintenir les pistes. Le suivi d'obstacles




Figure 4.1 — Structure haut niveau d'un système de surveillance

est un élément indispensable pour un système de détection d'obstacles. Son rôle est de déterminer le nombre, la position, et le mouvements des différentes pistes. Un système de pistage repose sur plusieurs briques dont la principale est celle qui permet une estimation récursive de l'état de la piste (position, vitesse, voire accélération). Cette brique s'appuie sur une méthode de filtrage telle que le filtrage de Kalman ou le filtrage particulaire. D'autres briques comme l'initialisation, la destruc-

tion, l'association des pistes sont indispensables au bon fonctionnement (voir figure 4.2). En effet,




Figure 4.2 — Un module de pistage

toutes les mesures délivrées par les capteurs ne sont pas forcément des mesures d'obstacles mais peuvent provenir d'interférences aléatoires (conditions atmosphériques, fausses alarmes,...). Il est donc nécessaire de valider les mesures qui correspondent le mieux à l'estimation : c'est l'association. Une piste tentée est typiquement issue d'une mesure non associée avec les pistes existantes. La confirmation d'une piste est basée sur le nombre de mises à jour effectuées pendant un temps fixé : c'est l'initialisation. Une piste est dite supprimée si elle n'est pas mise à jour par une mesure pendant un laps de temps fixé : c'est la destruction.

L'estimation récursive des caractéristiques de l'obstacle à suivre sera abordée dans une première partie. La deuxième partie décrit les autres briques nécessaires à la gestion des pistes (association, initialisation, destruction). Enfin, des résultats seront présentés pour différentes sources d'informations avec des comparaisons sur les estimations faites par les méthodes utilisées.

## 4.1 Estimation récursive des caractéristiques de la piste

Le pistage est utilisé afin de fournir la description d'un système dynamique. Il s'agit d'estimer à l'instant  $k$  l'état  $X_k$  d'un système, à partir d'observations  $(Z_0, \dots, Z_k)$  entachées d'un bruit blanc. Les observations seules ne permettent pas d'estimer cet état et il est nécessaire d'établir un modèle

suffisamment réaliste pour représenter l'évolution de l'état entre deux instants d'observations.

Considérons le modèle d'évolution d'une piste (obstacle à suivre) suivant :

$$X_k = f_{k-1}(X_{k-1}, V_{k-1}) \quad (4.1)$$

où  $f_{k-1} : \mathcal{R}^{n_x} \times \mathcal{R}^{n_v} \rightarrow \mathcal{R}^{n_x}$  est une fonction, pouvant être non linéaire, de l'état  $X_{k-1}$ , et de  $V_{k-1}$  qui représente le bruit sur l'état dont la distribution de probabilité est  $p_{V_{k-1}}(\cdot)$ .  $n_x$  et  $n_v$  sont les dimensions du vecteur d'état et du bruit. Ce modèle décrit un processus aléatoire qui a la propriété que son évolution (passage de  $X_k$  à  $X_{k-1}$ ) ne dépend que de l'état courant et non de son passé. C'est un chaîne de Markov i.e :

$$p(X_k/X_{k-1}, Z_{1:k-1}) = p(X_k/X_{k-1}) \quad (4.2)$$

L'objectif du suivi est d'estimer récursivement  $X_k$  à partir des mesures :

$$Z_k = h_k(X_k, W_k) \quad (4.3)$$

où  $h_k : \mathcal{R}^{n_x} \times \mathcal{R}^{n_w} \rightarrow \mathcal{R}^{n_z}$  est une fonction de  $X_k$  pouvant être non linéaire, et  $W_k$  est le bruit sur les mesures dont la distribution de probabilité est  $p_{W_k}(\cdot)$ .  $n_z$  et  $n_w$  sont les dimensions du vecteur de mesure et du bruit de mesure.

#### 4.1.1 Estimation bayésienne

Le problème de suivi d'un obstacle, du point de vue bayésien, peut être vu comme le calcul récursif de degrés de croyance en l'état  $X_k$  au temps  $k$ , en prenant en compte l'historique des mesures  $Z_{1:k} = Z_1, \dots, Z_k$ . Il est donc nécessaire de construire la densité de probabilité a posteriori (notée pdf dans la suite)  $p(X_k/Z_{1:k})$ . On considère que la pdf initiale est connue et est donnée par  $p(X_0/Z_0) \equiv p(X_0)$ . Alors, par principe, la pdf  $p(X_k/Z_{1:k})$  peut être obtenue récursivement en deux étapes : la prédiction et la mise à jour.

La première étape consiste en la prédiction à partir de  $p(X_{k-1}/Z_{1:k-1})$  (supposée connue à l'instant  $k-1$ ) en utilisant le modèle Markovien définie en 4.1, afin d'obtenir  $p(X_k/Z_{1:k-1})$  via l'équation de



Chapman-Kolmogorov [83] [104] :

$$p(X_k/Z_{1:k-1}) = \int p(X_k/X_{k-1})p(X_{k-1}/Z_{1:k-1})dX_{k-1} \quad (4.4)$$

$p(X_k/X_{k-1})$  est une densité de transition définie par le système d'équation 4.1. La deuxième étape utilise la règle de Bayes afin de mettre à jour  $p(X_k/Z_{1:k})$  en fonction des nouvelles mesures. On a :

$$p(X_k/Z_{1:k}) = \frac{p(Z_k/X_k)p(X_k/Z_{1:k-1})}{p(Z_k/Z_{1:k-1})} \quad (4.5)$$

où d'après l'équation de Chapman-Kolmogorov :

$$p(Z_k/Z_{1:k-1}) = \int p(Z_k/X_k)p(X_k/Z_{1:k-1})dX_k \quad (4.6)$$

dépend de la fonction de vraisemblance  $p(Z_k/X_k)$  définie par le modèle de mesure 4.3. Il est aussi possible d'obtenir une formule récursive pour cette distribution :

$$p(X_{k+1}/Z_{1:k+1}) = p(X_k/Z_{1:k}) \frac{p(Z_{k+1}/X_{k+1})p(X_{k+1}/X_k)}{p(Z_{k+1}/Z_{1:k})} \quad (4.7)$$

La solution optimale bayésienne est basée sur les relations récurrentes 4.4 et 4.5. Cependant, ces relations ne permettent pas un calcul analytique de la densité de probabilité. Sous certaines hypothèses, des solutions optimales ou sous-optimales existent. Si les modèles d'état et de mesure sont linéaires et les bruits considérés comme gaussiens alors les équations de Kalman [58], ou des méthodes numériques (grid-based method [3]) permettent une estimation optimale. Cependant, la condition de linéarité et l'hypothèse gaussienne sont strictes pour certaines applications. D'autres méthodes permettent une estimation sous-optimale dans des cas non-linéaires ou non-gaussiens : EKF (Extended Kalman Filter [10]), UKF (Unscented Kalman Filter [102]), méthodes numériques approximées (approximated grid-based method[3]), filtre à particules [45]. Une description précise de ces méthodes est donnée dans [87]. Les filtres basés sur les méthodes de Kalman (EKF, UKF) supposent la pdf

$p(X_k/Z_k)$  gaussienne, ils ne sont donc pas adaptés si celle-ci ne peut pas être considérée comme gaussienne. Les "grid-based method" souffrent de la croissance exponentielle de la complexité de leur algorithmes. Les filtres à particules, quant à eux, basés sur les méthodes de Monte-Carlo, sont des systèmes qui permettent une estimation dans des cas non-linéaires et non-gaussiens. Dans la suite, on présentera les méthodes, utilisées dans notre système, basées sur les filtres de Kalman et les méthodes particulières.

#### 4.1.2 Filtre de Kalman

Les filtres de Kalman sont des méthodes récursives qui supposent que la densité de probabilité de l'état conditionné par les mesures est une loi normale d'espérance l'estimation de l'état  $X_k$  et de variance la covariance sur cet état  $P_k$ .

$$p(X_k/Z_k) \sim N(X_k, P_k)$$

Si on considère que  $p(X_{k-1}/Z_{k-1})$  est gaussienne alors  $p(X_k/Z_k)$  est aussi gaussienne si :

- les bruits sur l'état, et de mesure sont indépendants et gaussiens. Selon cette hypothèse on a :

$$V_{k-1} \sim N(0, Q_{k-1})$$

$$W_k \sim N(0, C_k)$$

où  $Q_{k-1}$  et  $C_k$  modélisent respectivement les covariances du bruit sur l'état et du bruit sur la mesure.

- $f_{k-1}(X_{k-1}, V_{k-1})$  est une fonction linéaire connue
- $h_{k-1}(X_k, W_k)$  est une fonction linéaire connue

On a donc, à partir des équations 4.4 et 4.5 :

$$p(X_{k-1}/Z_{k-1}) \sim N(\tilde{X}_{k-1/k-1}, P_{k-1/k-1})$$

$$p(X_k/Z_{k-1}) \sim N(\hat{X}_{k/k-1}, P_{k/k-1})$$

$$p(X_k/Z_k) \sim N(\tilde{X}_{k/k}, P_{k/k})$$

De plus, les systèmes 4.1 et 4.3 peuvent s'écrire :

$$X_k = F_{k-1}X_{k-1} + V_{k-1} \quad (4.8)$$

$$Z_k = H_k X_k + W_k \quad (4.9)$$

où  $F_{k-1}$  et  $H_k$  sont des matrices connues définies par les fonctions linéaires  $f_{k-1}$  et  $h_k$ . Sous ces hypothèses, l'utilisation des équations de Kalman [58] permet une estimation optimale de l'état de notre obstacle.

Cet algorithme est une solution optimale sous les conditions de linéarité et gaussienne. Une autre méthode existe si les fonctions  $h_k$  ou/et  $f_{k-1}$  sont non linéaires : le filtre de Kalman étendu (EKF). Elle consiste en une linéarisation locale en approximant les fonctions non-linéaires par le premier terme du développement en série de Taylor. On a :

$$\hat{X}_{k/k-1} = f_{k-1}(\tilde{X}_{k-1/k-1}) \quad (4.10)$$

$$\tilde{X}_{k/k} = \hat{X}_{k-1/k} + K_k(Z_k - h_k(\hat{X}_{k/k-1})) \quad (4.11)$$

et les matrices  $F_{k-1}$  et  $H_k$  sont les matrices jacobiennes utilisées pour la linéarisation. Ces méthodes supposent toujours que  $p(X_k/Z_k)$  est gaussienne. Dans le cas de forte non linéarité, le caractère non gaussien de la pdf devient de plus en plus prononcé et la performance d'un tel filtre sera dégradée. La méthode basée sur le filtre UKF<sup>1</sup> nécessite aussi le caractère gaussien de la pdf  $p(X_k/Z_k)$ . Cet

---

<sup>1</sup>Unscented Kalman Filter

algorithme, récent, est décrit dans [102, 57]. Contrairement à l'EKF, l'UKF n'approxime pas les fonctions non-linéaires  $f_{k-1}$  et  $h_k$  mais approxime la pdf  $p(X_k/Z_k)$  par une densité gaussienne représentée par un ensemble d'échantillons choisis de façon déterministe. La première phase de ce filtrage sera donc la représentation de cette densité à l'instant  $k-1$  par un ensemble de  $N$  points  $X_{k-1}^i$  pondérés par  $W_{k-1}^i$ ,  $i = 0, \dots, N-1$ . L'étape de prédiction est alors réalisée :

$$\hat{X}_{k/k-1} = \sum_{i=0}^{N-1} W_{k-1}^i f_{k-1}(X_{k-1}^i) \quad (4.12)$$

$$\hat{P}_{k/k-1} = Q_{k-1} + \sum_{i=0}^{N-1} W_{k-1}^i [f_{k-1}(X_{k-1}^i) - \hat{X}_{k/k-1}] [f_{k-1}(X_{k-1}^i) - \hat{X}_{k/k-1}]^t \quad (4.13)$$

La pdf prédite  $p(X_k/Z_{k-1})$  est représentée par un ensemble de  $N$  échantillons :

$$X_{k/k-1}^i = f_{k-1}(X_{k-1}^i) \quad (4.14)$$

La mesure prédite est donnée par :

$$\hat{Z}_{k/k-1} = \sum_{i=0}^{N-1} W_{k-1}^i h_k(X_{k/k-1}^i) \quad (4.15)$$

et la mise à jour est effectuée par les relations suivantes :

$$\tilde{X}_{k/k} = \hat{X}_{k/k-1} + K_k(Z_k - \hat{Z}_{k/k-1}) \quad (4.16)$$

$$\tilde{P}_{k/k} = \hat{P}_{k/k-1} - K_k S_k K_k^t \quad (4.17)$$

où

$$K_k = P_{xz} S_k^{-1} \quad (4.18)$$

$$S_k = R_k + P_{zz} \quad (4.19)$$

$$P_{xz} = \sum_{i=0}^{N-1} W_{k-1}^i (X_{k/k-1}^i - \hat{X}_{k/k-1}) (h_k(X_{k/k-1}^i) - \hat{Z}_{k/k-1})^t \quad (4.20)$$

$$P_{zz} = \sum_{i=0}^{N-1} W_{k-1}^i (h_k(X_{k/k-1}^i) - \hat{Z}_{k/k-1}) (h_k(X_{k/k-1}^i) - \hat{Z}_{k/k-1})^t \quad (4.21)$$

Toutes les méthodes basées sur ce type de filtre ne diffèrent que par la sélection des échantillons (nombre, valeur, poids).

En résumé, si la pdf  $p(X_k/Z_k)$  peut être approximée par une gaussienne, les méthodes s'appuyant sur les filtres de Kalman délivrent des estimations optimales/sous optimales selon les conditions de linéarité/non-linéarité des modèles d'état 4.1 et de mesure 4.3.

### 4.1.3 Filtre à particules

Le filtrage particulaire, développé à l'origine dans [45], connaît actuellement un fort développement dans de nombreux domaines (vision, localisation, navigation, robotique,...), en particulier dans le pistage multi-cibles.

Ce filtrage est une méthode séquentielle de Monte-Carlo dans laquelle des particules parcourent l'espace d'état de manière indépendante, et interagissent sous l'effet d'une fonction de vraisemblance qui concentre automatiquement les particules dans les régions d'intérêt de l'espace d'état. En fait, à chaque instant  $k$ , une particule a d'autant plus de chance de se reproduire à l'instant suivant qu'elle est cohérente avec l'observation courante. Cette méthode a l'avantage de ne pas nécessiter de contraintes linéaires ou gaussiennes sur le modèle. De plus, elle est très facile à implémenter, puisqu'il suffit de savoir simuler de manière indépendante différentes trajectoires du modèle.

Pour détailler cet algorithme, supposons que l'on soit capable de simuler  $N_S$  échantillons aléatoires à

partir de  $p(X_{0:k}/Z_{1:k})$  :

$$\{X_{0:k}^i\}_{i=0}^{N_S-1}$$

On pourra par exemple prendre cette approximation pour représenter la densité de probabilité a posteriori :

$$p(X_{0:k}/Z_{1:k}) \approx \frac{1}{N_S} \sum_{i=0}^{N_S-1} \delta(X_{0:k} - X_{0:k}^i) \quad (4.22)$$

où  $\delta$  est une fonction de Dirac. Cette approximation converge vers la densité de probabilité si  $N_S$  est suffisamment grand (loi des grands nombres)[31].

Cependant, il est habituellement impossible d'échantillonner efficacement à partir de  $p(X_{0:k}/Z_{1:k})$  à chaque instant  $k$  puisque cette distribution n'est pas connue et doit être estimée. Une solution consiste à échantillonner à partir d'une distribution connue  $q(X_{0:k}/Z_{1:k})$ . C'est le principe d'échantillonnage d'importance (Importance Sampling [32]). On introduit une densité d'importance (fonction d'importance)  $q(\cdot)$  telle que  $p(\cdot) \propto q(\cdot)$ , à partir de laquelle on échantillonnera  $N_S$  particules. Alors, une approximation de la distribution quand  $N_S$  est grand est donnée par [3] :

$$p(X_{0:k}/Z_{1:k}) = \sum_{i=0}^{N_S-1} w_{0:k}^i \delta(X_{0:k} - X_{0:k}^i) \quad (4.23)$$

$$\tilde{w}_{0:k}^i = \frac{p(X_{0:k}^i/Z_{1:k})}{q(X_{0:k}^i/Z_{1:k})} \quad (4.24)$$

$$w_{0:k}^i = \frac{\tilde{w}_{0:k}^i}{\sum_{i=0}^{N_S-1} \tilde{w}_{0:k}^i} \quad (4.25)$$

où les  $\tilde{w}_{0:k}^i, w_{0:k}^i$  sont respectivement les poids non normalisés et les poids normalisés.

Cette méthode n'est cependant pas adéquate pour une estimation récursive. En effet, on a besoin

d'avoir toutes les mesures  $Z_{1:k}$  pour estimer  $p(X_{0:k}/Z_{1:k})$ . La méthode précédente peut être modifiée pour qu'il devienne possible de calculer l'estimée de  $p(X_{0:k}/Z_{1:k})$  sans utiliser tout l'historique de l'état. Il faut choisir la densité d'importance telle que :

$$q(X_{0:k}/Z_{1:k}) = q(X_{0:k-1}/Z_{1:k-1})q(X_k/X_{0:k-1}, Z_{1:k}) \quad (4.26)$$

En utilisant les équations 4.7, 4.24 et 4.26 on a :

$$\tilde{w}_k^i = \frac{p(X_{k-1}^i/Z_{1:k-1})p(Z_k/X_k^i)p(X_k^i/X_{k-1}^i)}{q(X_{0:k-1}^i/Z_{1:k-1})p(Z_k/Z_{1:k-1})q(X_k^i/X_{0:k-1}^i, Z_{1:k})} \quad (4.27)$$

$$\tilde{w}_k^i = \tilde{w}_{k-1}^i \frac{p(Z_k/X_k^i)p(X_k^i/X_{k-1}^i)}{p(Z_k/Z_{1:k-1})q(X_k^i/X_{0:k-1}^i, Z_{1:k})} \propto \tilde{w}_{k-1}^i \frac{p(Z_k/X_k^i)p(X_k^i/X_{k-1}^i)}{q(X_k^i/X_{0:k-1}^i, Z_{1:k})} \quad (4.28)$$

De plus, on n'a besoin que d'une estimation de  $p(X_k/Z_{1:k})$ . On ne garde donc en mémoire que  $X_k^i$ . Les séquences  $X_{0:k-1}^i$  et l'historique des mesures  $Z_{1:k-1}$  ne sont plus nécessaires. La formule de récurrence pour les poids modifiés est donc :

$$\tilde{w}_k^i = \tilde{w}_{k-1}^i \frac{p(Z_k/X_k^i)p(X_k^i/X_{k-1}^i)}{q(X_k^i/X_{k-1}^i, Z_k)} \quad (4.29)$$

Cet algorithme consiste donc en la propagation récursive des particules et de leurs poids associés à chaque réception de mesure.

Cependant, un problème commun à tous ces types d'algorithmes est le phénomène de dégénérescence des particules. En effet, après quelques itérations, les descendants d'une même particule qui a été multipliée occupent toutes la même position. Toutes ces particules ont un poids négligeable sauf une. Une mesure caractéristique de cette dégénérescence est définie par [70] :

$$N_{eff} = \frac{N_s}{1 + Var(w_k^{*i})} \quad (4.30)$$

où  $w_k^{*i} = \frac{p(X_k^i/Z_{1:k})}{q(X_k^i/X_{k-1}^i, Z_k)}$  est défini comme "poids vrai". Cependant, on ne peut pas l'évaluer exactement.

On utilise donc un estimée de  $N_{eff}$  qui peut être obtenu par :

$$\hat{N}_{eff} = \frac{1}{\sum_{i=0}^{N_S-1} (w_k^i)^2} \quad (4.31)$$

La dégénérescence est d'autant plus forte que  $\hat{N}_{eff}$  est petit. Une approche brute pour réduire ce phénomène est d'augmenter considérablement  $N_S$ , ce qui est le plus souvent impraticable. Plusieurs méthodes pour réduire ce phénomène existent. La première consiste à effectuer un choix adéquate pour la fonction d'importance. La seconde repose sur l'utilisation d'un rééchantillonnage. Toutes les variantes du filtrage particulaire se différencient par le choix de la densité d'importance et/ou la modification du rééchantillonnage.

Une méthode consiste à choisir la densité d'importance de telle façon qu'elle minimise la variance des poids d'importance conditionnellement à la trajectoire simulée et aux mesures  $Z_{0:k}$ . Cette fonction d'importance est  $p(X_k/X_{k-1}^i)$  [30] i.e :

$$q(X_k^i/X_{k-1}^i) = p(X_k/X_{k-1}^i) \quad (4.32)$$

A partir de l'équation 4.29 on obtient :

$$\tilde{w}_k^i = \tilde{w}_{k-1}^i p(Z_k/X_k^i) \quad (4.33)$$

Cela semble être le meilleur choix pour la fonction d'importance puisque celle ci permet un calcul des poids de manière intuitive et simple. Dans la suite, cette densité d'importance sera conservée.

Une autre méthode consiste à rééchantillonner les particules quand le phénomène de dégénérescence est significatif. Pour ceci, si  $\hat{N}_{eff} < seuil$ , on tire (avec remplacement)  $N_S$  particules parmi le jeu courant, de façon à favoriser les particules de plus forte vraisemblance (de plus fort poids). Le poids affecté à chaque particule est alors fixé à l'inverse du nombre de particules. Même si cette méthode réduit le phénomène de dégénérescence, d'autres problèmes apparaissent. En effet, les particules de plus fort poids sont statistiquement sélectionnées plusieurs fois ce qui provoque la perte de diversité à travers les particules. Les particules ne sont concentrées qu'autour d'un seul point. Des techniques



existent pour résoudre ce problème : "resample move algorithm [44]", "regularisation [81]".

De nombreuses variantes du filtrage particulaire utilisant le rééchantillonnage sont décrites dans [51]. Une des variantes les plus courantes, consiste à effectuer un rééchantillonnage systématique (même si  $\hat{N}_{eff} > seuil$ ). On parle ici de filtre SIR (Sampling Importance Resampling) ou encore de "bayesian bootstrap" [45]. Les hypothèses émises pour l'utilisation de cet algorithme sont limitées. Il faut premièrement connaître les fonctions caractérisant la dynamique de l'état et des mesures (4.1 et 4.3 respectivement). Il faut ensuite pouvoir échantillonner à partir de la distribution du bruit et de  $p(X_k/X_{k-1}^i)$  utilisée ici comme densité d'importance. En effet, un échantillon  $X_k^i$  de  $p(X_k/X_{k-1}^i)$  peut être engendré par la génération d'un échantillon de bruit  $V_{k-1}^i$  à partir de  $p_{V_{k-1}}(V_{k-1})$  d'une part et par l'utilisation du modèle défini en 4.1 :  $X_k^i = F_k(X_{k-1}^i, V_{k-1}^i)$  d'autre part.

Chaque poids est donc calculé à partir de l'équation 4.33 et puisque  $\forall i, w_{k-1}^i = \frac{1}{N_S}$  on a :

$$w_k^i = p(Z_k/X_k^i) \quad (4.34)$$

Il faut donc connaître aussi la fonction de vraisemblance. On désigne par :

$$p_{W_k}(Z_k - H_k(X_k^i)) \quad (4.35)$$

la fonction de vraisemblance, qui quantifie l'adéquation de chaque particule  $X_k^i$  par rapport à l'observation courante  $Z_k$  : cette fonction dépend de l'écart  $Z_k - H_k(X_k^i)$  entre l'observation  $H_k(X_k^i)$  à laquelle on s'attend si le système occupait l'état  $X_k^i$ , et l'observation réelle  $Z_k$  [68] : c'est l'innovation. Avant chaque rééchantillonnage, les poids calculés à partir de la vraisemblance 4.34 sont normalisés. L'algorithme ci-dessous décrit deux variantes du filtrage particulaire suivant la méthode de rééchantillonnage effectuée.

**INITIALISATION (i)  $k = 0$** 

Un jeu de  $N_S$  particules est généré à partir de la valeur initiale du vecteur d'état  $X_0$

$$X_k^i \sim p(X_0)$$

Chaque poids est calculé en fonction de la vraisemblance : c'est la pondération

$$w_0^i = p_{W_0}(Z_0 - H_0(X_0^i)), \forall i = 1, \dots, N_S$$

à tout instant  $k \geq 1$

**PREDICTION (ii)**

On génère des échantillons de bruit sur l'état

$$V_k^i \sim p_{V_k}(\cdot), \forall i = 1, \dots, N_S$$

chaque particule est donnée par

$$X_k^i = F_k(X_{k-1}^i, V_k^i), \forall i = 1, \dots, N_S$$

**PONDERATION (iii)**

$$w_k^i = w_{k-1}^i p_{W_k}(Z_k - H_k(X_k^i)), \forall i = 1, \dots, N_S$$

normalisation :

$$w_{0:k}^i = \frac{w_{0:k}^i}{\sum_{i=1}^{N_S} w_{0:k}^i}, \forall i = 1, \dots, N_S$$

**REECHANTILLONNAGE (iv)**

Importance Sampling	Sampling Importance Resampling Bayesian Bootstrap
si $\hat{N}_{eff} = \frac{1}{\sum_{i=1}^{N_S} (w_k^i)^2} < seuil$ on tire (avec remplacement) $N_S$ particules parmi le jeu courant	on tire (avec remplacement) $N_S$ particules parmi le jeu courant $\forall i, w_k^i = \frac{1}{N_S}$

## 4.2 Performances des estimateurs récursifs : borne de Cramer Rao a posteriori

Le choix de la méthode d'estimation à appliquer est guidé par sa performance. Pour un système qui vérifie les conditions gaussienne et de linéarité, alors le filtre de Kalman est optimal. Cependant, dans le cas non linéaire, on ne peut pas conclure sur l'optimalité du système. On utilise donc des comparaisons avec des bornes caractérisant la performance optimale. On a vu, dans 3.2.5.2, qu'il existait une borne inférieure sur la variance des erreurs dans le cas d'estimations de paramètres déterministes. Cette notion a été étendue dans le cas d'estimation de variables aléatoires [100] : borne de Cramer Rao a posteriori<sup>2</sup>. Plus récemment, dans [98], l'auteur propose une formule récursive pour le calcul de cette borne.

### 4.2.1 Calcul récursif de la matrice d'information de Fisher

On considère le système défini par le modèle d'évolution et le modèle de mesure définis respectivement en 4.1 et 4.3. Si  $\hat{X}_{k/k}$  est un estimateur non biaisé de  $X_k$ , calculé à partir de la séquence de mesures  $Z_k = z_1, \dots, z_k$  et de la connaissance de  $p(X_0)$  (pdf initiale), alors la matrice de covariance de  $\hat{X}_{k/k}$ , notée  $P_{k/k}$  admet une borne minimale donnée par :

$$P_{k/k} \triangleq E\{(\hat{X}_{k/k} - X_k)(\hat{X}_{k/k} - X_k)^t\} \geq J_k^{-1} \quad (4.36)$$

où la matrice  $J_k$  est la matrice d'information de Fisher que l'on cherche à déterminer.

#### 4.2.1.1 Cas général

Tichavsky et al [98] proposent une méthode pour calculer  $J_k$  récursivement :

$$J_{k+1} = D_k^{22} - D_k^{21}(J_k + D_k^{11})^{-1}D_k^{12} \quad (4.37)$$

où

$$D_k^{11} = E\{-\Delta_{X_k}^{X_k} \log p(X_{k+1}/X_k)\} \quad (4.38)$$

---

<sup>2</sup>PCRB : Posterior Cramer Rao Bound

avec  $\Delta_{\Theta}^{\Xi} = \nabla_{\theta} \nabla_{\Xi}^t$

$$D_k^{12} = E\{-\Delta_{X_k}^{X_{k+1}} \log p(X_{k+1}/X_k)\} \quad (4.39)$$

$$D_k^{21} = E\{-\Delta_{X_{k+1}}^{X_k} \log p(X_{k+1}/X_k)\} = [D_k^{12}]^t \quad (4.40)$$

$$D_k^{22} = E\{-\Delta_{X_{k+1}}^{X_{k+1}} \log p(X_{k+1}/X_k)\} + E\{-\Delta_{z_{k+1}}^{X_{k+1}} \log p(z_{k+1}/X_{k+1})\} \quad (4.41)$$

Les espérances  $E\{\cdot\}$  dans (4.38), (4.39), et (4.40) sont calculées à partir de  $X_k$  et  $X_{k+1}$  alors que celle utilisée dans l'équation (4.41) est évaluée à partir de  $X_k$ ,  $X_{k+1}$  et  $z_{k+1}$ .

#### 4.2.1.2 Cas de Bruit gaussien

Le système est défini par :

$$X_{k+1} = f_k(X_k) + v_k \quad (4.42)$$

$$z_{k+1} = h_{k+1}(X_{k+1}) + w_{k+1}$$

où les bruits  $v_k$  et  $w_{k+1}$  sont des bruits blanc, gaussiens et indépendants. Leurs covariances respectives sont données par  $Q_k$  et  $R_{k+1}$ . On montre facilement que dans ce cas :

$$D_k^{11} = E\{\tilde{F}_k^t Q_k^{-1} \tilde{F}_k\} \quad (4.43)$$

où

$$\tilde{F}_k = [\nabla_{X_k} f_k^t(X_k)]^t \quad (4.44)$$

est la matrice jacobienne de  $f_k(X_k)$  évaluée à la vraie valeur  $X_k$ .

$$D_k^{12} = -E\{\tilde{F}_k^t\} Q_k^{-1} = [D_k^{21}]^t \quad (4.45)$$

$$D_k^{22} = Q_k^{-1} + E\{\tilde{H}_{k+1}^t R_{k+1}^{-1} \tilde{H}_{k+1}\} \quad (4.46)$$

où

$$\tilde{H}_{k+1} = [\nabla_{X_{k+1}} h_{k+1}^t(X_{k+1})]^t \quad (4.47)$$

est la matrice jacobienne de  $h_{k+1}(X_{k+1})$  évaluée à la vraie valeur de  $X_{k+1}$ . Le problème est de calculer les espérances qui apparaissent dans (4.46), (4.45) et (4.43). Néanmoins, une approximation de Monte Carlo pourra être appliquée. On créera un ensemble de réalisations de vecteurs d'états, trajectoires, et l'espérance sera calculée sur la moyenne de cet ensemble.

### 4.2.1.3 Cas linéaire et gaussien

Le cas linéaire et gaussien est donné par le système 4.42 avec :

$$f_k(X_k) = F_k X_k \quad (4.48)$$

$$h_{k+1}(X_{k+1}) = H_{k+1} X_{k+1} \quad (4.49)$$

En remarquant que les jacobiens sont maintenant donnés par :

$$\tilde{F}_k = F_k \quad (4.50)$$

$$\tilde{H}_{k+1} = H_{k+1} \quad (4.51)$$

on montre que :

$$D_k^{11} = F_k^t Q_k^{-1} F_k \quad (4.52)$$

$$D_k^{12} = -F_k^t Q_k^{-1} = [D_k^{21}]^t \quad (4.53)$$

$$D_k^{22} = Q_k^{-1} + H_{k+1}^t R_{k+1}^{-1} H_{k+1} \quad (4.54)$$

Finalement, l'équation récursive pour la matrice de Fisher est :

$$J_{k+1} = Q_k^{-1} + H_{k+1}^t R_{k+1}^{-1} H_{k+1} - Q_k^{-1} F_k (J_k + F_k^t Q_k^{-1} F_k)^{-1} F_k^t Q_k^{-1} \quad (4.55)$$

Si on suppose que la matrice de covariance est telle que  $P_{k/k}^{-1} = J_k^{-1}$  alors en utilisant le lemme d'inversion matricielle<sup>3</sup> on montre que :

$$P_{k+1/k+1}^{-1} = (Q_k + F_k J_k^{-1} F_k^t)^{-1} + H_{k+1}^t R_{k+1}^{-1} H_{k+1} \quad (4.56)$$

Une nouvelle application du lemme d'inversion matricielle montre que :

$$P_{k+1/k+1} = P_{k+1/k} - P_{k+1/k} H_{k+1}^t (H_{k+1} P_{k+1/k} H_{k+1}^t + R_{k+1})^{-1} H_{k+1} P_{k+1/k} \quad (4.57)$$

On retrouve, dans ce cas, l'équation de Kalman pour la covariance sur les erreurs d'estimation définie par :

---

<sup>3</sup> $(A + BCB^t)^{-1} = A^{-1} - A^{-1}B(B^tA^{-1}B + C^{-1})^{-1}B^tA^{-1}$

$$P_{k+1/k+1} = P_{k+1/k}K_{k+1}S_{k+1}K_{k+1}^t \quad (4.58)$$

avec

$$S_{k+1} = H_{k+1}P_{k+1/k}H_{k+1}^t + R_{k+1} \quad (4.59)$$

et

$$K_{k+1} = P_{k+1/k}H_{k+1}^tS_{k+1}^{-1} \quad (4.60)$$

Dans le cas linéaire et gaussien, l'utilisation des équations de Kalman rend l'estimateur efficace, i.e. la borne de Cramer Rao est atteinte pour la covariance sur les erreurs.

#### 4.2.1.4 Cas déterministe

En l'absence de bruit, l'évolution de l'état est complètement déterministe. Les espérances n'ont plus besoin d'apparaître et on a comme forme récursive l'équation suivante :

$$J_{k+1} = [\tilde{F}_k^{-1}]^t J_k \tilde{F}_k^{-1} + \tilde{H}_{k+1}^t R_{k+1}^{-1} \tilde{H}_{k+1} \quad (4.61)$$

## 4.2.2 PCRB dans le cas linéaire : distribution beta et gaussienne

### 4.2.2.1 Calcul de la borne

cas gaussien : voir 4.2.1.2

**cas beta** Si les mesures sont bornées par un intervalle, i.e  $Z \in [P_L, P_H]$ , la distribution la plus appropriée pour modéliser  $Z$  est la distribution beta [19]. Sa pdf est donnée par :

$$p(Z) = \frac{\Gamma(\lambda_1 + \lambda_2)}{\Delta P \Gamma(\lambda_1) \Gamma(\lambda_2)} \left( \frac{Z - P_L}{\Delta P} \right)^{\lambda_1 - 1} \left( 1 - \frac{Z - P_L}{\Delta P} \right)^{\lambda_2 - 1} \quad (4.62)$$

où  $\Delta P = P_H - P_L$ ;  $\lambda_1, \lambda_2$  sont des paramètres de forme et le symbole  $\Gamma$  représente la fonction gamma. La figure 4.3 représente cette fonction pour  $\lambda_1 = \lambda_2 = 1.1$ ,  $P_L = 22.5$  et  $P_H = 45$ . On suppose ici que la mesure est une distance comprise entre  $P_L$  et  $P_H$  (observations de distance radiale donnée par le radar par exemple). On souhaite maintenant calculer la borne de Cramer Rao du système définie ci-dessous :




Figure 4.3 — La densité de probabilité de la mesure : distribution beta

$$\begin{aligned} X_{k+1} &= FX_k + v_k \\ Z_{k+1} &= HX_{k+1} + w_k \end{aligned} \quad (4.63)$$

où, pour l'application concernant les observations radar, on a :

$$\begin{aligned} X_k &= \begin{pmatrix} r_k \\ \dot{r}_k \end{pmatrix} \\ Z_k &= \begin{pmatrix} r_{obs_k} \\ \dot{r}_{obs_k} \end{pmatrix} \end{aligned} \quad (4.64)$$

$$F = \begin{pmatrix} 1 & T \\ 0 & 1 \end{pmatrix} \quad (4.65)$$

pour un modèle à vitesse constante et  $H = Id_2$ . Pour le bruit, on suppose qu'il est gaussien pour l'évolution. Du côté des mesures, le bruit suit une loi de distribution beta pour la distance radiale et une loi normale pour la vitesse radiale. On a donc :

$$\begin{aligned} v_k &\sim N(0, GG^t) \\ w_k &= \begin{pmatrix} w_{1k} \sim \beta(\lambda_1, \lambda_2) \\ w_{2k} \sim N(0, \sigma_{\dot{r}_{obs_k}}^2) \end{pmatrix} \end{aligned} \quad (4.66)$$

où  $G = [T^2/2T]^T$  et  $Q = \sigma_f^2$ . L'utilisation de la formule récursive donnée en 4.37 et des conditions propres à notre système montre que :

$$D_k^{11} = F^t (GQG^t)^{-1} F \quad (4.67)$$

$$D_k^{12} = -F^t (GQG^t)^{-1} = [D_k^{21}]^t \quad (4.68)$$

$$D_k^{22} = (GQG^t)^{-1} + E\{-\Delta_{X_{k+1}}^{X_{k+1}} \log p(Z_{k+1}/X_{k+1})\} \quad (4.69)$$

En posant  $B_k = E\{-\Delta_{X_{k+1}}^{X_{k+1}} \log p(Z_{k+1}/X_{k+1})\}$  et en utilisant le lemme d'inversion matricielle on démontre que :

$$J_{k+1} = B_k + (GQG^t + FJ_k^{-1}F^t)^{-1} \quad (4.70)$$

Le calcul de  $B_k$  est donné ci-dessous. Etant donné notre système, en particulier le modèle de bruit sur les mesures, on a :

$$p(Z_{k+1}/X_{k+1}) = c \left( \frac{r_{k+1} - P_l(r_{obs_{k+1}})}{\Delta P} \right)^{(\lambda_1 - 1)} \left( 1 - \frac{r_{k+1} - P_l(r_{obs_{k+1}})}{\Delta P} \right)^{(\lambda_2 - 1)} e^{-\frac{1}{2\sigma_f^2}(r_{obs_{k+1}} - r_{k+1})} \quad (4.71)$$

$$\frac{\partial \log p(Z_{k+1}/X_{k+1})}{\partial r_{k+1}} = (\lambda_1 - 1) \left( \frac{1}{r_{k+1} - P_l(r_{obs_{k+1}})} \right) + (\lambda_2 - 1) \left( \frac{1}{r_{k+1} - P_l(r_{obs_{k+1}}) - \Delta P} \right) \quad (4.72)$$

$$\frac{\partial^2 \log p(Z_{k+1}/X_{k+1})}{\partial r_{k+1}^2} = -(\lambda_1 - 1) \left( \frac{1}{r_{k+1} - P_l(r_{obs_{k+1}})} \right)^2 - (\lambda_2 - 1) \left( \frac{1}{r_{k+1} - P_l(r_{obs_{k+1}}) - \Delta P} \right)^2 \quad (4.73)$$

$$\frac{\partial^2 \log p(Z_{k+1}/X_{k+1})}{\partial r_{k+1} \partial \dot{r}_{k+1}} = \frac{\partial^2 \log p(Z_{k+1}/X_{k+1})}{\partial \dot{r}_{k+1} \partial r_{k+1}} = 0 \quad (4.74)$$

$$\frac{\partial^2 \log p(Z_{k+1}/X_{k+1})}{\partial \dot{r}_{k+1}^2} = -\frac{1}{\sigma_f^2} \quad (4.75)$$

Finalement, la matrice  $B_k$  est définie par :

$$B_k = \begin{pmatrix} E \left( \frac{\lambda_1 - 1}{(r_{k+1} - P_l(r_{obs_{k+1}}))} + \frac{\lambda_2 - 1}{(r_{k+1} - P_l(r_{obs_{k+1}}) - \Delta P)} \right) & 0 \\ 0 & \frac{1}{\sigma_f^2} \end{pmatrix} \quad (4.76)$$

Cependant, dans le cas où les dénominateurs s'annulent, i.e. l'état rencontre les bornes, alors les termes non nuls de  $B_k$  tendent vers l'infini. Il en résulte une convergence rapide de la pcrb de  $r_k$  vers zéro. Pour contourner, ce problème on suppose que si  $|r_{K+1} - P_l(r_{obs_k})| < \ell$  alors  $P_l(r_{obs_k}) = P_l(r_{obs_k}) - \kappa$  et  $\Delta P = \Delta P + \kappa$ ; et si  $|r_{K+1} - P_l(r_{obs_k}) - \Delta P| < \ell$  alors  $\Delta P = \Delta P + \kappa$ .



#### 4.2.2.2 Simulation : scénario en ligne droite

On propose ici d'évaluer la PCRB pour l'estimation de distance et vitesse radiale dans le cas où la mesure est issue du radar. On considère ici que le bruit sur l'observation de distance radiale suit une distribution beta ou gaussienne, celui de la vitesse radiale est considéré gaussien. Le scénario étudié est un scénario de suivi en ligne droite. On suppose qu'un véhicule s'éloigne à une vitesse relative de  $10 \text{ m/s}$ . L'initialisation de  $J = P_0^{-1}$  est donnée par :

$$P_0 = \begin{pmatrix} 100 & 0 \\ 0 & 10 \end{pmatrix} \quad (4.77)$$

Pour le problème aux bornes, on utilise  $\ell = \kappa = 1 \text{ m}$ . La figure 4.4 représente la racine carré de la pcrb de la distance radiale pour les deux types de distribution. Pour des scénarios de courte durée (inférieure à  $2s$  ici : dépend du premier changement de porte), la pcrb est légèrement supérieure pour la distribution beta (environ  $1 \text{ m}$ ). Néanmoins, pour les deux types de distributions, les pcrb convergent (ici vers  $0.5 \text{ m}$  pour une durée de  $20s$  : environ 2500 mesures). Pour la vitesse radiale, la pcrb est indépendante du choix de la distribution effectué pour la distance (figure 4.5).




Figure 4.4 — Borne De Cramer Rao de la distance radiale selon la distribution du bruit

Etant donné les résultats présentés ci-dessus, on pourra approximer la distribution du bruit sur l'observation de distance radiale par une gaussienne. La figure 4.6 propose une représentation de la




Figure 4.5 — Borne De Cramer Rao de la vitesse radiale

gaussienne utilisée. Ces paramètres sont donnés par [19] :

$$E(r) = Pl(r) + \Delta P \frac{\lambda_1}{\lambda_1 + \lambda_2} \quad (4.78)$$

$$\sigma_r = \sqrt{\frac{\Delta P^2 \lambda_1 \lambda_2}{(\lambda_1 + \lambda_2)^2 (\lambda_1 + \lambda_2 + 1)}} \quad (4.79)$$

Si  $\Delta P = 22.5$  et  $\lambda_1 = \lambda_2 = 1.1$  alors  $\sigma_r \approx 6.29 m$ .

Le calcul de la pcrb sur  $r$  nous a permis de valider le fait que la distribution gaussienne peut être choisie pour caractériser le bruit sur l'observation de distance radiale. Dans la suite, cette approximation sera utilisée.

### 4.2.3 PCRb dans le cas non linéaire

On propose ici de caractériser la borne dans le cas où on souhaite estimer le vecteur d'état défini par :

$$X_k = \begin{pmatrix} x_k \\ \dot{x}_k \\ y_k \\ \dot{y}_k \end{pmatrix} \quad (4.80)$$




Figure 4.6 — Distribution gaussienne et beta

à partir des observations :

$$Z_k = \begin{pmatrix} r_k \\ \dot{r}_k \\ \omega_k \end{pmatrix} \quad (4.81)$$

On rappelle que les composantes du vecteur  $X_k$  sont les caractéristiques cinématiques de la cible dans un repère cartésien. Les mesures sont les observations de distance et vitesse radiale et de vitesse angulaire du cap. Le modèle d'évolution est défini par

$$X_{k+1} = FX_k + v_k \quad (4.82)$$

où

$$F = \begin{pmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (4.83)$$

et  $v_k \sim N(0, Q_k)$ .

Le modèle non linéaire est :

$$Z_{k+1} = h_{1_{k+1}}(X_{k+1}) = h_{k+1}(X_{k+1}) + w_k \quad (4.84)$$

avec :

$$r_k = \sqrt{x_k^2 + y_k^2} \quad (4.85)$$

$$\dot{r}_k = h_{2_{k+1}}(X_{k+1}) = \frac{x_k \dot{x}_k + y_k \dot{y}_k}{\sqrt{x_k^2 + y_k^2}} \quad (4.86)$$

$$\omega_k = h_{3_{k+1}}(X_{k+1}) = \frac{x_k \dot{y}_k - \dot{x}_k y_k}{x_k^2 + y_k^2} \quad (4.87)$$

et  $w_k \sim N(0, R_k)$ . Les bruits  $v_k$  et  $w_k$  sont considérés indépendants.

#### 4.2.3.1 Calcul de la borne

Le calcul de la borne est donné dans 4.2.1.2 puisque l'on travaille dans le cas gaussien. On a donc dans le cas où  $f_k$  est linéaire et  $h_k$  non linéaire :

$$J_{k+1} = D_k^{22} - D_k^{21} (J_k + D_k^{11})^{-1} D_k^{12} \quad (4.88)$$

avec

$$D_k^{11} = F_k^t Q_k^{-1} F_k \quad (4.89)$$

$$D_k^{12} = -F_k^t Q_k^{-1} = [D_k^{21}]^t \quad (4.90)$$

$$D_k^{22} = Q_k^{-1} + E\{\tilde{H}_{k+1}^t R_{k+1}^{-1} \tilde{H}_{k+1}\} \quad (4.91)$$

où

$$\tilde{H}_{k+1} = [\nabla_{X_{k+1}} h_{k+1}^t(X_{k+1})]^t = \begin{pmatrix} \frac{\partial h_1}{\partial x} & \frac{\partial h_1}{\partial \dot{x}} & \frac{\partial h_1}{\partial y} & \frac{\partial h_1}{\partial \dot{y}} \\ \frac{\partial h_2}{\partial x} & \frac{\partial h_2}{\partial \dot{x}} & \frac{\partial h_2}{\partial y} & \frac{\partial h_2}{\partial \dot{y}} \\ \frac{\partial h_3}{\partial x} & \frac{\partial h_3}{\partial \dot{x}} & \frac{\partial h_3}{\partial y} & \frac{\partial h_3}{\partial \dot{y}} \end{pmatrix}_{k+1} (X_{k+1}) \quad (4.92)$$

### 4.2.3.2 Simulation : scénario en virage

On propose ici d'évaluer la PCRB pour l'estimation des caractéristiques cinématiques de la cible dans un repère cartésien. Le scénario spécifié permet de préciser les performances optimales dans le cas du suivi d'un obstacle en virage, à partir d'observations de distance et vitesse radiale et vitesse angulaire de cap. La cible se déplace à la vitesse  $v = 10 \text{ m/s}$  le long d'une clothoïde définie par le rayon de courbure  $R$ . Selon le bruit de mesure sur la vitesse angulaire, on calcule les pcrbs des composantes du vecteur d'état. Les figures 4.7, 4.8 décrivent respectivement ces résultats. La pcrb sur  $x$  est fortement dépendante de la précision que l'on a sur  $\omega$  pour des scénarios d'une durée inférieure à 60 s. Pour un scénario d'une durée de 120 s, la pcrb converge vers la même valeur quel que soit la variance sur  $\omega$ . En début de scénario, le mouvement étant longitudinal, la pcrb sur  $x$  augmente. Pour la distance et la vitesse suivant  $y$ , on s'aperçoit que les pcrbs sont identiques (à 10 cm près) et ont tendance à augmenter puisqu'en fin de scénario le mouvement du véhicule tend vers un mouvement plus transversal que longitudinal. L'initialisation de la matrice de Fisher  $J_0$ , est donnée à partir de la matrice de covariance initiale  $P_0$  :

$$J_0 = P_0^{-1} = \begin{pmatrix} 1.4 & 0 & 0 & 0 \\ 0 & 5 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0.25 \end{pmatrix}^{-1} \quad (4.93)$$

Ensuite, on analyse l'effet du rayon de courbure sur la pcrb. Les figures 4.9 et 4.10 montrent les pcrbs obtenues pour différents  $R$ . Plus on tend vers un scénario en ligne droite, plus la performance sur l'estimation de  $x$  diminue. En effet, les mouvements selon l'axe  $x$  (transversaux) sont quasiment nuls pour une cible se déplaçant sur une courbe qui tend vers la ligne droite.




Figure 4.7 — PCRB de  $x$  et  $v_x$  en fonction de  $\sigma_\omega$  ( $rad/s$ )




Figure 4.8 — PCRB de  $y$  et  $v_y$  en fonction de  $\sigma_\omega$  ( $rad/s$ )




Figure 4.9 — PCRB de  $x$  et  $v_x$  en fonction du rayon de courbure




Figure 4.10 — PCRB de  $y$  et  $v_y$  en fonction du rayon de courbure

## 4.3 Gestion des pistes

### 4.3.1 Association des pistes

Dans la partie précédente, nous avons présenté deux types de filtres de poursuite qui permettent une estimation de l'état de l'obstacle à suivre. Ces filtres ont pour rôle de suivre une trajectoire étant données les observations qui lui sont associées. Dans de nombreuses applications radar, par exemple, les mesures ne sont pas seulement issues des cibles à suivre mais aussi du bruit et d'objets divers (barrières de sécurité, panneaux, terrain, ...). Il est donc nécessaire de sélectionner les mesures, si elles existent, correspondant le mieux à la piste. Les mesures non désirées sont généralement qualifiées de "clutter". De plus, dans un contexte multipiste, les mesures peuvent être issues de plusieurs cibles. Les cibles peuvent, à tout instant, rentrer et sortir de la zone de surveillance du capteur. Un capteur a rarement une probabilité de détection  $P_D = 1$  et une probabilité de fausses alarmes  $P_F = 0$ . Dans ce contexte, de nombreux critères, pour prendre la décision d'associer des mesures ou une mesure à une piste, existent. Ces critères dépendent essentiellement de la complexité de la tâche du pistage, comme par exemple le nombre de pistes, les manoeuvres effectuées par les obstacles, le nombre de fausses alarmes. Dans un contexte de pistage en présence de "clutter", une des premières phases essentielles pour l'association de donnée est le fenêtrage [8]. Le fenêtrage permet de ne pas prendre en considération les mesures qui sont loin de la mesure prédite et de sélectionner les mesures ayant la plus forte probabilité d'entretenir la piste. Après cette sélection de mesures, il est nécessaire de faire des choix quant aux associations éventuelles. De nombreuses méthodes existent dans la littérature. On pourra citer par exemple comme méthode d'association la méthode simple du plus proche voisin (PPV) [37] qui est une méthode à hypothèse unique [55]. Ce type de méthode sous-optimale, est adapté aux environnements contenant peu d'événements et connaît de faibles performances en présence de "clutter". Dans [8], les auteurs décrivent une méthode optimale, d'un point de vue bayésien, pour l'association de données. Cette méthode nécessite la connaissance de toutes les mesures de l'instant initial à l'instant courant et utilise le théorème des probabilités totales. Cette méthode ne peut donc pas être implémentée puisque le nombre d'hypothèses croît exponentiellement avec le temps.

D'autres méthodes sous-optimales, ont donc été proposées. Ces méthodes peuvent être classées en deux classes [80] : mono-scan et multi-scan. Les algorithmes mono-scan (PDAF, JPDAF [8]) délivrent



un état estimé courant à partir d'un état précédent et d'hypothèses sur l'origine de la détection à l'instant courant. Au contraire les algorithmes multi-scan (Multiple Hypothesis Tracking [85], VDA [91]) construisent l'état estimé courant à partir d'hypothèses sur les mesures courantes et précédentes. Le nombre d'hypothèses à sauvegarder est fixé. Ces algorithmes sont généralement plus efficaces quand la probabilité de détection  $P_D$  est faible et que les "clutters" sont nombreux ou non homogènes. Pour nos capteurs, dont les probabilités de fausses alarmes sont faibles, on utilisera essentiellement une méthode d'association basée sur la recherche du plus proche voisin.

#### 4.3.1.1 Fenêtrage

Le but de cette sélection de mesure est d'intégrer au filtre les bonnes mesures et éviter les calculs inutiles en cas de présence de "clutters". Cette méthode élimine les mesures qui sont "loin" de la mesure prédite issue du filtrage. Le fenêtrage est effectué pour chaque piste et à chaque instant par la définition d'une zone de surveillance appelée fenêtre (ou région d'intérêt). Une seule ou l'ensemble des mesures présentes dans cette région est sélectionné pour l'association, les autres sont ignorées. La taille de la fenêtre influence le nombre de mesures validées. Si on choisit une fenêtre trop petite alors la probabilité d'éliminer la mesure provenant de la cible augmente, ce qui peut provoquer la perte de la piste. Au contraire, si la taille est trop grande, un grand nombre de mesures ne provenant pas de la piste est utilisé. Cela tend à augmenter les calculs et à détériorer la précision du pistage. Un résumé de diverses méthodes de fenêtrage est donné dans [15]. La plupart de ces méthodes utilise des styles de fenêtres ellipsoïdaux (voir figure 4.11).

La fenêtre est formée de telle façon que la probabilité qu'une mesure, issue de la cible, soit dans la fenêtre de validation, à condition que la cible existe et soit détectée, est donnée par une probabilité  $P_G$  évaluée à partir des caractéristiques statistiques de la piste. Puisque la taille ou le volume de la région dépendent de la précision du pistage, la fenêtre varie à chaque instant et pour chaque piste.

En supposant que la mesure provienne de la cible est un événement de densité de probabilité normale, centrée sur la mesure prédite ( $\hat{Z}_k = H(\hat{X}_k)$ ) i.e. :  $p(Z_k/Z_{1:k-1}) = N(\hat{Z}_k, S_k)$ , la fenêtre de validation  $G$  est définie par :

$$G = \{Z / (Z - \hat{Z}_k)^t S_k^{-1} (Z - \hat{Z}_k) < \gamma\} \quad (4.94)$$




Figure 4.11 — Une fenêtre ellipsoïdale

où  $S_k$  représente la covariance de l'innovation  $v_k = Z - \hat{Z}_k$ . Le volume de la fenêtre est donnée par [8] :

$$V_m = C_m |\gamma S_k|^{1/2} \quad (4.95)$$

où  $|\gamma S_k|$  est le déterminant de  $\gamma S_k$  et  $C_m$  vaut  $\frac{\pi^{m/2}}{m!}$  si  $m$  est pair et  $\frac{2^{m+1}(\frac{m+1}{2})!}{(m+1)!} \pi^{\frac{m-1}{2}}$  si  $m$  est impair. Le seuil  $\gamma$  est un paramètre directement issu de la probabilité  $P_G$ . Il est issu des tables du  $\chi^2$  à  $m$  degrés de liberté avec un niveau de confiance de  $N\%$ .

Des techniques de fenêtrage, où les cibles ne suivent pas un modèle à vitesse constante ("maneuvering target"), sont détaillées dans [103]. Dans la plupart des méthodes de pistage, en présence de "clutter", le volume de la fenêtre est utilisé pour mesurer la densité de "clutter" qui est nécessaire pour la caractérisation des probabilités d'associations. Le calcul de ce volume, pour un pistage mono-cible considérant une approximation gaussienne (tel que le filtre à association probabiliste des données : PDAF), est donné par l'équation 4.95 [56]. Cependant, pour un pistage qui approxime la densité de probabilité a posteriori par une combinaison de gaussiennes ou par un ensemble de particules, le volume est l'union de toutes les régions d'intérêt. Ceci s'applique aussi pour le pistage multi-cible, puisque même si on utilise une approximation gaussienne (filtre à association conjointe des données : JPDAF), les fenêtres de validation de deux cibles proches se chevauchent. Le calcul du volume d'une région composée de plusieurs hyper-ellipses est donc nécessaire. Dans ce contexte,

des méthodes de calcul de ce volume sont présentées dans [79]. Une méthode consiste à employer une simulation de Monte-Carlo qui génère des échantillons dans une région englobant la fenêtre et qui compte la proportion d'échantillons appartenant à la fenêtre. Une autre méthode [77] considère comme mesure de chevauchement le nombre de mesures partagées entre les différentes fenêtres. Après avoir sélectionner les mesures valides, il faut utiliser une méthode d'association afin de mettre à jour l'estimation de l'état. Ces méthodes sont diverses suivant le contexte du pistage. Quelques unes sont présentées dans la suite.

#### 4.3.1.2 Méthode du plus proche voisin (PPV)

L'algorithme du plus proche voisin [8], noté PPV dans la suite, détermine, par l'utilisation de distances (traditionnellement euclidienne ou de Mahalanobis), quelle mesure est la plus proche de la prédiction et associe cette mesure à la piste. Cependant, puisque l'on n'associe qu'une seule mesure, il est parfois possible de ne pas associer la mesure issue de la cible dans différents cas. Le premier cas est celui où le capteur délivre des mesures non issues d'un obstacle (voir figure 4.12). Si une telle mesure appartient à la fenêtre de validation, rien ne dit qu'elle ne sera pas la plus proche.




Figure 4.12 — Cas 1 : association PPV

De plus, si un capteur délivre plusieurs mesures pour une seule et même cible, on ne prendra pas en compte toutes les données de la cible, ce qui peut entraîner une perte de précision du système de pistage.

Le choix du calcul de distance (euclidienne, Mahalanobis) peut conduire à des associations incorrectes. Dans le cas de la figure 4.13, la donnée sera associée à la piste de gauche en considérant une distance de Mahalanobis alors qu'elle est plus proche de celle de droite en considérant une métrique euclidienne. Au contraire, pour le cas de la figure 4.14, la donnée sera associée avec la piste de droite en considérant une distance euclidienne alors qu'elle est plus proche de celle de gauche en considérant une distance de Mahalanobis. Afin de palier ce problème, une nouvelle distance a été proposée dans [55] : c'est une pondération entre les distances euclidienne et de Mahalanobis, en fonction de la taille de la fenêtre de validation.




Figure 4.13 — Cas 2 : association PPV




Figure 4.14 — Cas 3 : association PPV

Dans le cas d'un suivi de deux cibles proches où les modules de pistage ne communiquent pas entre eux, cet algorithme peut conduire, dans des cas critiques en particulier le croisement de deux obstacles, à la perte de suivi d'une piste. Une étude réalisée par [82] montre que la méthode PPV a des performances acceptables pour un système de pistage présentant très peu de "clutters". Les auteurs proposent une comparaison des résultats respectifs aux méthodes d'association utilisées. Cette com-

paraison se base sur le temps de vie d'une piste, sur l'erreur moyenne de l'estimation de position et sur la complexité des calculs. Pour des niveaux de "clutter" faibles, les résultats prouvent que la méthode PPV propose un temps de vie supérieure aux autres méthodes, une erreur d'estimation de position équivalente aux autres méthodes, et une complexité moindre. Dans le cas d'une présence importante de "clutters" ces performances se dégradent puisqu'on n'utilise qu'une seule mesure de la fenêtre de validation.

### 4.3.2 Initialisation et mort des pistes : vraies ou fausses pistes

Ces briques d'un système de pistage dépendent fortement du contexte et des capteurs. En effet, les systèmes d'association de données évoluent dans des situations où les mesures ne sont pas certaines. On sait que dans de nombreuses applications, notamment radar, les mesures peuvent provenir de cibles ou de fausses détections (divers objets, terrain, bruit thermique,...). Dans des contextes multicibles, les mesures peuvent provenir d'une cible ou d'une autre. Dans de telles conditions, un système d'initialisation des pistes crée des vraies pistes (à partir des mesures d'une cible) et des fausses pistes (à partir des fausses mesures). Durant l'opération de maintenance des pistes, une vraie piste peut devenir fausse si la détection n'a pas eu lieu, ou si le filtre utilisé ne modélise pas les manoeuvres effectuées par la piste. De façon équivalente, une fausse piste peut devenir une vraie piste si les mesures issues d'une cible sont utilisées pour la mise à jour. Il est donc nécessaire de distinguer les vraies des fausses pistes. Quand une piste est considérée comme vraie, elle est intégrée au traitement suivant. Quand une piste est considérée comme fausse, on dit qu'elle est morte ou terminée. Pour distinguer un fausse piste d'une vraie, les systèmes de pistage utilisent en général une mesure de qualité pour la piste considérée. Les divers algorithmes de pistage utilisent des noms différents pour cette mesure de qualité. On parlera d'une fonction de score de piste ("track score function") pour le MHT (Multiple Hypothesis Tracking)[15], d'une probabilité d'existence de piste pour le IPDA (Integrated Probability Data Association) [78] ou de probabilité de détection de piste pour le IMM-PDA (Integrated Multiple Model Probability Data Association)[7]. La procédure usuelle est de considérer une piste comme vraie si sa qualité est au-dessus d'un seuil : on parlera de seuil de confirmation. Elle considère, de plus, qu'une piste est fausse si sa qualité est inférieure à un seuil : on parlera de seuil de terminaison. Dans de nombreux cas, ces différents seuils sont constants. Cependant, dans [9], les

auteurs proposent des seuils qui évoluent avec l'âge de la piste. L'initialisation et la terminaison des pistes sont donc basées sur une mesure de qualité. Cette mesure dépend fortement du contexte et sera décrite dans nos applications suivant les capteurs utilisés.

## 4.4 Application : simulation de suivi d'obstacles par Lidar et Radar

Pour les deux types de capteur, on choisit de construire un composant fonctionnel pour chaque tâche différente du pistage. On aura donc une brique pour la "vie des pistes", une brique pour l'association de données et une brique pour l'estimation. On traite ici les résultats sur l'estimation des caractéristiques cinématiques de l'obstacle. On suppose que l'initialisation et que l'association de données sont réalisées. Les résultats sur ces briques seront appréhendés dans le chapitre sur les résultats expérimentaux (6). On admet donc que les observations sont issues d'une seule et même cible et que la probabilité de non détection des capteurs est nulle. On aborde ici deux cas de scénario : la ligne droite et le virage. On supposera, parfois, que l'on a accès à la courbure de la route à l'endroit considéré ; en particulier dans le cas de l'estimation à partir des observations radar seules.

### 4.4.1 Estimation par lidar

On rappelle que le lidar délivre des observations dans un repère cartésien. Le vecteur de mesure est donc :

$$Z = \begin{pmatrix} x \\ y \end{pmatrix} \quad (4.96)$$

Le vecteur d'état est définie par :

$$X = \begin{pmatrix} x \\ \dot{x} \\ y \\ \dot{y} \end{pmatrix} \quad (4.97)$$

pour un modèle d'évolution à vitesse constante. Pour un modèle à accélération constante on inclut l'accélération longitudinale et transversale au vecteur d'état. Les deux modèles d'évolution utilisés

sont donc :

- un modèle à vitesse constante :

$$X_{k+1} = F_{VC}X_k + G_{VC}V_k \quad (4.98)$$

où

$$F_{VC} = \begin{pmatrix} 1 & \Delta t & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & \Delta t \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (4.99)$$

$$G_{VC} = \begin{pmatrix} \frac{\Delta t^2}{2} & 0 \\ \Delta t & 0 \\ 0 & \frac{\Delta t^2}{2} \\ 0 & \Delta t \end{pmatrix} \quad (4.100)$$

Le bruit sur le modèle est considéré ici comme étant l'accélération. Il est caractérisé par sa matrice de covariance  $Q$  dont les éléments diagonaux pourront être fixés par l'étude réalisée en 3.2.3.

- un modèle à accélération constante :

$$X_{k+1} = F_{AC}X_k + G_{AC}V_k \quad (4.101)$$

où

$$F_{AC} = \begin{pmatrix} 1 & \Delta t & \frac{\Delta t^2}{2} & 0 & 0 & 0 \\ 0 & 1 & \Delta t & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & \Delta t & \frac{\Delta t^2}{2} \\ 0 & 0 & 0 & 0 & 1 & \Delta t \\ 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix} \quad (4.102)$$

$$G_{AC} = \begin{pmatrix} \frac{\Delta t^3}{6} & 0 \\ \frac{\Delta t^2}{2} & 0 \\ \Delta t & 0 \\ 0 & \frac{\Delta t^3}{6} \\ 0 & \frac{\Delta t^2}{2} \\ 0 & \Delta t \end{pmatrix} \quad (4.103)$$

Le bruit sur le modèle est considéré ici comme étant le jerk (dérivée de l'accélération). Il est caractérisé par sa matrice de covariance  $Q$ .

#### 4.4.1.1 scénario ligne droite

On suppose ici qu'un cible s'éloigne à la vitesse  $v = 5 \text{ m/s}$  de l'observateur. Sa trajectoire suit une ligne droite. On génère des observations toutes les  $\Delta t_{lidar} = 600 \text{ m/s}$ . Les mesures sont calculées à partir de la vraie valeur en affectant du bruit à celle ci selon les caractéristiques du capteur. La figure 4.15 illustre les mesures générées et la vraie trajectoire. Les figures 4.16 4.17 représentent les erreurs




Figure 4.15 — Description de la trajectoire et des observations bruitées

au sens des moindres carrés sur l'estimation des composantes cinématiques. Au vu de ces figures, les deux modèles sont équivalents pour l'estimation de la position. Néanmoins, le modèle à accélération constante génère une erreur moindre pour l'estimation des vitesses. La précision sur les vitesses étant



faible, quelque soit le modèle, le choix du modèle sera guidé par l'application considérée.




Figure 4.16 — Erreur sur  $x$  et  $\dot{x}$  pour les deux modèles




Figure 4.17 — Erreur sur  $y$  et  $\dot{y}$  pour les deux modèles

#### 4.4.1.2 scénario en virage

Le scénario utilisé est celui définie en 3.2.5.1. Les figures 4.18 et 4.19 renseignent sur la rmse sur les différentes composantes du vecteur d'état. De manière identique au scénario en ligne droite, on

peut dire que le choix du modèle est pratiquement sans influence sur l'erreur de position. Cependant, la précision sur la vitesse étant moindre pour le modèle à accélération constante pour un scénario en virage, on utilisera ce type de modèle.




Figure 4.18 — Erreur sur  $x$  et  $\dot{x}$  pour les deux modèles




Figure 4.19 — Erreur sur  $y$  et  $\dot{y}$  pour les deux modèles

#### 4.4.2 Estimation par radar

On rappelle que le radar délivre des observations radiales toutes les 8 ms. La mesure de distance est caractérisée par une observation de porte distance et la mesure de vitesse par un indice vitesse. Le vecteur de mesures est :

$$z = \begin{pmatrix} r \\ \dot{r} \end{pmatrix} \quad (4.104)$$

La définition du modèle d'évolution est dépendante de l'application à réaliser. En effet, si le scénario est un scénario en ligne droite, l'estimation de  $r$  et  $\dot{r}$  pourra être suffisante dans un contexte d'anti-collision. Par contre pour la gestion des interdistances, en particulier pour le suivi en virage, l'estimation des positions et des vitesses cartésiennes sera nécessaire.

##### 4.4.2.1 Estimation linéaire à partir des observations de distance et vitesse radiale

On utilise ici un modèle d'évolution à vitesse constante dont le vecteur d'état est équivalent au vecteur de mesures. Le problème est donc linéaire, on exploitera donc un filtre de Kalman. La figure 4.20 décrit la définition du scénario et en particulier les observations effectuées (mesure de porte distance). La figure 4.21 renseigne sur la rmse de  $r$ . On remarque que l'on est capable d'estimer la

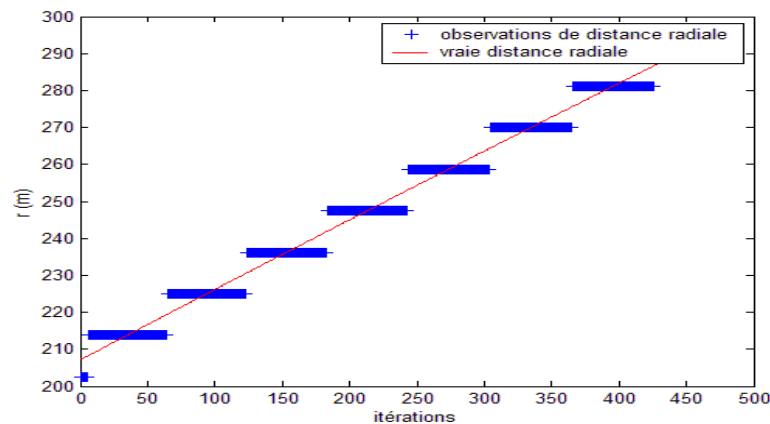


Figure 4.20 — Scénario pour la distance radiale

distance radiale avec environ 1 m de précision pour un scénario de 5 s environ. La performance est




Figure 4.21 — Erreur sur  $r$  : covariance kalman et rmse

donc moindre que celle obtenue par régression linéaire (voir 3.2.1 :  $\approx 0.5 m$  pour une durée de 1.2 s). Afin d'améliorer la précision sur la distance, on pourra initialiser le filtre par les composantes issues de la régression linéaire.

#### 4.4.2.2 Estimation non linéaire : scénario en virage

Le scénario présenté ici est un scénario d'estimation séquentielle de la trajectoire d'une cible qui roule dans un virage. Le scénario pourra s'inclure dans un système de gestion des interdistances, en particulier dans un contexte de suivi en virage. On suppose ici qu'une cartographie GPS précise de la route nous permet de connaître la courbure de la route à l'endroit considéré. A partir de cette courbure  $R$  et de la vitesse  $v$  de la cible, la vitesse angulaire du cap du véhicule sera calculée :  $\omega = v/R$ . Les observations sont les mesures issues du radar :  $r$  et  $\dot{r}$ . Avant l'estimation séquentielle de la trajectoire, on procède par régression linéaire pour estimer de manière précise la distance radiale du véhicule. On supposera pour l'initialisation du filtre que les composantes  $y_0$  et  $\dot{y}$  sont données par  $r$  et  $\dot{r}$  issue de la régression. La matrice de covariance, pour  $y$  et  $\dot{y}$ , sera initialisée par l'estimation de l'erreur donnée par la régression. Pour l'initialisation sur les composantes  $x$  et  $\dot{x}$ , on suppose que la cible se déplace au centre de sa voie (largeur 5 m). On pourra en utilisant la cartographie de la route générer des observations sur  $x$  centrées sur la voie et de covariance  $\sigma_x = 1.4 m$  (voir 4.79). La vitesse transversale initiale est considérée nulle. Sa covariance est fixée à  $\sigma_{\dot{x}} = 10 m/s$ .

Le modèle d'évolution utilisé est donné par :

$$X_{k+1} = F(\omega)X_k + w_k \quad (4.105)$$

où  $F(\omega)$  est définie par 3.83 et la matrice de covariance de  $w_k$  par 3.82. Le modèle de mesure est :

$$z_k = \begin{pmatrix} x_k \\ \sqrt{x_k^2 + y_k^2} \\ \frac{x_k \dot{x}_k + y_k \dot{y}_k}{\sqrt{x_k^2 + y_k^2}} \end{pmatrix} + w_k = h(X_k) + w_k \quad (4.106)$$

Pour l'estimation séquentielle, le modèle de mesure étant non linéaire, on utilise un filtre de Kalman étendu ou un filtrage particulaire. Les figures 4.22 et 4.23 présentent les résultats sur l'estimation séquentielle de la trajectoire du véhicule pour les deux méthodes. Les données, représentées en jaune, caractérisent les observations bruitées faites sur  $x$ . La trajectoire réelle du véhicule est en rouge. Les bords gauche et droit sont en vert. L'estimation de la trajectoire est donnée en noir. Ces figures montrent que l'on est capable de reconstruire la trajectoire d'une manière séquentielle précise à partir d'observations bruitées, en particulier sur  $x$  et  $r$ .




Figure 4.22 — Estimation de la trajectoire par filtre de kalman étendu




Figure 4.23 — Estimation de la trajectoire par filtrage particulaire

## 4.5 Conclusion

Dans cette section, on a abordé le problème de l'estimation récursive des caractéristiques cinématiques de la cible à suivre. Selon, les observations utilisées, donc les capteurs, les modèles mis en jeu sont différents. Pour les observations laser, le filtrage de Kalman convient puisque ces mesures sont précises et linéaires par rapport au vecteur d'état à estimer. Dans ce cas, aucune hypothèse sur la cartographie de la route n'est nécessaire. Cependant, si on souhaite estimer ces caractéristiques avec les observations radar seules, on a vu que la condition d'observabilité était difficilement atteignable. Il est donc nécessaire d'inclure des observations caractérisant la chaussée. On utilisera en particulier pour un scénario en virage, la courbure de la route et sa largeur ; en supposant que la cible suit la route. Cependant, ces données ne sont pas nécessairement accessibles. Dans ce cas, il est nécessaire d'utiliser toutes les informations disponibles et en particulier tous les capteurs. Dans la section suivante, on présente donc la fusion des estimations données par les différents capteurs afin de s'affranchir des hypothèses réalisées dans cette section pour le suivi mono capteur.



## Chapitre 5

# LA FUSION PISTE A PISTE

Le pistage d'obstacles dans un environnement routier permet d'extraire des informations importantes pour la sécurité d'un conducteur. En effet, une estimation des caractéristiques cinématiques des obstacles (position, vitesse relative,...) permet une plus nette compréhension de la scène. Cette estimation est une des composantes primordiales d'un système d'alerte pour le conducteur. Un système de pistage s'appuie sur l'utilisation de mesures discrètes (position, vitesse) délivrées par un système sensoriel. L'utilisation d'au moins un capteur extéroceptif (Lidar, Radar, IR, Caméra visible,...) est donc nécessaire. Cependant, un seul capteur ne permet généralement pas de détecter rapidement dans toutes les directions, sous toutes les conditions atmosphériques tous les obstacles potentiellement dangereux. Ce système mono capteur peut parfois délivrer des fausses alarmes néfastes pour l'interprétation de l'environnement. La multiplication des capteurs permet de faire face à ces différents problèmes. Extraire le maximum d'informations possibles sur l'environnement éclairé par les différents capteurs sous toutes les conditions d'opérations est le but de la fusion de données multisensorielle.

Elle est vue ici comme la fusion de deux pistages d'obstacles délivrés par deux systèmes indépendants. Ces deux systèmes délivrent des estimations, des mesures caractérisant les données de positions et cinématiques des différents obstacles. Ces estimations sont basées sur l'utilisation de filtres de Kalman ou à particules et d'un système d'association de données.

La fusion de pistages va permettre d'utiliser opportunément les différentes caractéristiques complémentaires et redondantes délivrées par les deux systèmes. Les positions et les vitesses des cibles seront estimées d'une manière plus robuste, tout en procédant à l'élimination des fausses pistes. Cet



algorithme de fusion nécessite premièrement l'utilisation d'une architecture gérant les données à traiter et à envoyer au système d'alerte. Cette architecture est issue de la collaboration avec la SAGEM dans le cadre du projet PAROTO. De manière naturelle, une méthode d'association de pistages mono capteur est utilisée pour tester la ressemblance de deux pistes. Ce premier niveau est crucial pour le processus de fusion piste à piste. En effet, si les associations sont défectueuses alors l'estimation fusionnée des pistes peut potentiellement devenir décevante par rapport à un système de pistage mono capteur. Enfin, après une association fiable, il est nécessaire de combiner les pistages pour obtenir une interprétation de l'environnement plus robuste. Cette combinaison s'appuie sur l'utilisation de filtre de Kalman et filtres à particules.

L'architecture du système de fusion sera préalablement explicitée. Ensuite, la gestion du flux de données étant présentée, on détaillera l'algorithme d'association de pistages. La partie la plus riche sera celle correspondant à la combinaison des pistes qui s'appuie sur des méthodes basées sur les filtres de Kalman ou particulaires. Enfin, des résultats applicatifs concernant la fusion de pistes Lidar et Radar ou de pistes infrarouge et Radar seront commentés.

## 5.1 Architecture du système de fusion

On rappelle que ce travail a été réalisé dans le cadre d'une collaboration avec la SAGEM pour le projet PAROTO.

Les pistages locaux fournissent la meilleure information qu'il est possible d'extraire de l'analyse des données capteurs. Le module de fusion est en charge du recoupement de ces informations afin d'obtenir une carte des obstacles (faiblement typés) en exploitant les complémentarités géométrique (champs de vue) et cinématique des deux capteurs. Lorsque de nouvelles données sont disponibles, un événement "mise à jour" signale au module de fusion qu'il peut commencer le travail. Les données sont disponibles dans le module de réception. Les différentes tâches décrites figure 5.1 peuvent alors s'enchaîner séquentiellement. On peut distinguer deux parties dans le module. La partie dite de gestion de flux de données est l'ensemble des fonctions de mise à jour des données internes du module suite à la réception de données capteurs. Il s'agit le plus souvent de recopies. La partie dite analytique est l'ensemble des fonctions qui permet la création d'informations supérieures aux informations capteurs.




Figure 5.1 — schéma du module de fusion

Explicitons quelques termes. Une piste monomode est une piste formée au niveau d'un capteur, qui n'est pas associée à une piste provenant de l'autre capteur. Les nouvelles pistes capteurs arrivant au module de fusion sont forcément monomodes. Une piste bimode est une piste résultant de l'association d'une piste  $capteur_1$  et d'une piste  $capteur_2$ . Nous verrons par la suite qu'est appelé dissemblance, une mesure de la qualité d'association d'une piste  $capteur_1$  avec une piste  $capteur_2$ .

## 5.2 Gestion du flux de données

### 5.2.1 monomode

Ce bloc effectue la mise à jour des données internes. Les nouvelles pistes provenant du traitement des données capteurs sont inévitablement monomodes. Si une nouvelle observation associée à une piste monomode apparaît, alors cette piste est maintenue dans son état. Une nouvelle piste monomode est créée si l'observation reçue ne correspond à aucune piste du module de fusion.

Si aucune observation ne prolonge une piste du module de fusion, alors cette piste disparaît.

### 5.2.2 bimode

Si les deux pistes qui composent une piste bimode sont prolongées, la piste bimode est prolongée : maintenance bimode.

Si les deux pistes qui composent une piste bimode disparaissent, la piste bimode disparaît. Si une seule des 2 pistes formant la piste bimode est prolongée d'une nouvelle observation, alors la piste bimode est abandonnée et la piste prolongée passe au statut monomode.

## 5.3 Calcul des ressemblances

On essaie d'apparier une piste  $capteur_1$  avec une piste  $capteur_2$ . De nombreuses méthodes d'association sont présentées dans [90]. Pour associer deux pistes, il est nécessaire qu'elles soient dans la zone de recouvrement des champs de vue des deux capteurs. En pratique, les pistes des deux capteurs ne sont pas synchrones. Il est donc nécessaire de les synchroniser avant comparaison. La date

de référence est celle donnée par la piste la plus récemment mise à jour. On réalise une prédiction à cette date pour la piste la plus ancienne des deux. L'élaboration d'un test est donc nécessaire afin de choisir entre les deux hypothèses suivantes :

- $H_0$  : les estimées sont issues de la même cible
- $H_1$  : les estimées sont issues de cibles différentes

Le test pour l'association se situe dans l'espace des mesures commun aux deux capteurs et est inspiré des travaux effectués dans [8]. On considère donc les vecteurs  $x^1(k)$  et  $x^2(k)$ , de covariances associées  $p^1(k)$  et  $p^2(k)$ , projections des vecteurs d'état estimés  $X_k^1$  et  $X_k^2$  dans l'espace des mesures commun, de covariances associées  $P_k^1$  et  $P_k^2$ , à l'instant  $k$ .

En définissant  $\Delta^{12} = x^1(k) - x^2(k)$ , les hypothèses deviennent :

$$H_0 : \Delta^{12} = 0$$

et

$$H_1 : \Delta^{12} \neq 0$$

En supposant les erreurs indépendantes, la covariance de  $\Delta^{12}$  est :

$$p^{12}(k) = p^1(k) + p^2(k)$$

Les erreurs étant supposées gaussiennes :

$H_0$  est vraie si  $\Delta^{12}(k)^t [p^{12}(k)]^{-1} \Delta^{12}(k) \leq \delta$  où  $\delta$  un paramètre issu des tables du  $\chi^2$  puisque la distribution du test statistique ainsi considéré est approximativement une distribution du  $\chi^2$  à  $n$  degrés de liberté, où  $n$  est la dimension de l'état dans l'espace de mesures commun aux deux capteurs.

La valeur

$$fit = \Delta^{12}(k)^t [p^{12}(k)]^{-1} \Delta^{12}(k) \quad (5.1)$$

est appelée dissemblance des deux pistes.

Cependant, plusieurs pistes d'un capteur peuvent parfois s'associer avec une piste d'un autre capteur. Il est donc nécessaire de sélectionner la plus probable. Un algorithme basé sur l'approche standard du

plus proche voisin est utilisé. Finalement, les deux pistes ayant la plus petite valeur de dissemblance sont associées. Les deux pistes monomodes ainsi associées n'ont plus le statut de monomode mais sont bimodes. Il est maintenant nécessaire de combiner ces deux estimations afin d'en extraire une estimation plus précise.

## 5.4 La combinaison des pistes

De nombreuses méthodes de fusion de données pour le pistage existent dans la littérature, une bonne description de ces méthodes est visible dans [42]. Une des méthodes des plus intuitives est de fusionner les mesures des différents capteurs dans un module central capable de délivrer une estimation précise de l'état des obstacles. C'est une méthode centralisée de fusion des mesures [54][53]. Une autre méthode, dite décentralisée, consiste à fusionner les estimations délivrées par les différents pistages locaux [96][25][17][105]. Des comparaisons sont présentées dans [43][22]. De plus, on pourra faire rétroagir l'estimation fusionnée sur les pistages capteurs pour les adapter [107]. Le schéma de la figure 5.2 décrit ses différentes architectures. Ici on utilisera une méthode basée sur la fusion piste à piste sans rétroaction de l'estimation fusionnée. En effet, on cherche à développer une méthode générale de fusion de données pour le pistage facilement adaptable aux différentes sorties des modules de poursuite. On ne cherche pas à agir sur ces modules. Cette méthode pourra être utilisée pour fusionner des pistes Radar avec celles d'un Lidar, ou des pistes Radar avec des pistes IR, sans modifier les modules des pistages respectifs des deux capteurs. Chaque capteur sera vue comme une boîte noire en sortie de laquelle une estimation de l'état des obstacles et des mesures associées seront disponibles.

A l'entrée du module de fusion on aura donc un ensemble de vecteurs d'états correspondant à des pistes. Un module d'association de données est donc nécessaire pour regrouper les pistes émanant de la même cible. Cette procédure d'association effectuée, on utilisera les mesures des différents capteurs pour effectuer le filtrage. L'association des pistes étant décrites dans le paragraphe 5.3, on considère ici que les entrées du module de fusion sont des pistes associées. La combinaison, coeur du module de fusion, sera basé sur les filtres de Kalman et à particules SIR décrits ci-avant. La validation de l'estimation fusionnée sera effectuée par des calculs de divergence entre les mesures au niveau des capteurs et les pistes au niveau du module de fusion. On a vu auparavant, que le pistage utilise des




Figure 5.2 — Les architectures de fusion de pistages

observations bruitées et des modèles pour l'estimation d'un état "caché". De tels modèles ont parfois des contraintes de non-linéarité et les bruits d'états et de mesures sont parfois non-gaussien. Sous ces hypothèses, l'utilisation des filtres à particules est parfaitement adaptée. Toutefois, si les bruits sont supposés gaussiens, on pourra utiliser les filtres de Kalman si les modèles sont linéaires et les filtres de Kalman étendu si les modèles sont non linéaires. De nombreuses méthodes basées sur de tels filtres existent dans la littérature [17][95][96][43][109].

Différentes méthodes de fusion basées sur le filtrage particulaire sont décrites dans [107][23][52][33]. Dans [23], les pistages et le module de fusion interagissent pour obtenir un suivi de visage plus robuste. Le module de fusion utilise les sorties des pistages pour construire des hypothèses, et les pistages utilisent la sortie du module de fusion pour guider leurs poursuites. Les auteurs comparent deux architectures de fusion pour configurer leurs capteurs et estimer l'état de la cible. Dans la première méthode (dite centralisée), les capteurs sont configurés par l'ajustement d'un gain fovéal donné par les particules issues du rééchantillonnage. La fusion de données est accompli en utilisant des poids particulaires pour chaque capteur. Au contraire, dans la deuxième méthode (dite décentralisée), chaque

capteur utilise un filtre à particule pour estimer des mesures angulaires et pour effectuer sa propre configuration. La méthode centralisée donnent de meilleures performances pour leur application. Dans [52], les auteurs étendent l'utilisation classique des filtrages particuliers, par l'estimation de plusieurs processus d'état à partir de réalisations de différents processus de mesure. Cet algorithme est utilisé pour le pistage multi cibles dans un contexte où les mesures sont des données de direction. Dans [33], les auteurs présentent une méthode de pistage multi-cibles conjointe à une gestion des capteurs.

On présente ici deux méthodes d'estimation pour l'état fusionné. La première repose sur une combinaison réalisée à partir de filtre de Kalman tandis que l'autre méthode utilise les méthodes particulières afin de s'affranchir de l'hypothèse gaussienne sur les bruits.

#### 5.4.1 Consolidation bimode : filtre de kalman

L'association de deux pistes provenant de deux capteurs différents doit permettre d'améliorer la connaissance sur l'objet poursuivi. On se propose donc de réaliser un filtrage de Kalman, dont les observations sont les entrées des pistages locaux, i.e  $Z_k^1$  et  $Z_k^2$  (voir figure 5.3). Soit le vecteur d'état :

$$X^{12} = \begin{pmatrix} x_{12} \\ \dot{x}_{12} \\ y_{12} \\ \dot{y}_{12} \end{pmatrix}$$

où  $x_{12}$ ,  $y_{12}$  sont les positions de la piste dans le référentiel commun aux deux capteurs, et  $\dot{x}_{12}$ ,  $\dot{y}_{12}$  la vitesse relative de la piste. Le modèle d'évolution peut être présenté sous forme matricielle par :

$$X_{k+1}^{12} = F X_k^{12} + G V_k, V_k \sim N(0, Q_k)$$

où  $F$  est la matrice de transition qui modélise l'évolution de  $X_k^{12}$ , et  $Q_k$  la matrice de covariance de  $V_k$  modélisé par l'accélération.

$$F = \begin{pmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad G = \begin{pmatrix} T^2/2 & 0 \\ T & 0 \\ 0 & T^2/2 \\ 0 & T \end{pmatrix}$$

$$Q_k = \begin{pmatrix} \sigma_{ax_{12}}^2 & 0 \\ 0 & \sigma_{ay_{12}}^2 \end{pmatrix}$$

La méthode de fusion envisagée est illustrée sur la figure 5.3, et est inspirée par les travaux de J.B. Gao et C.J. Harris[43].

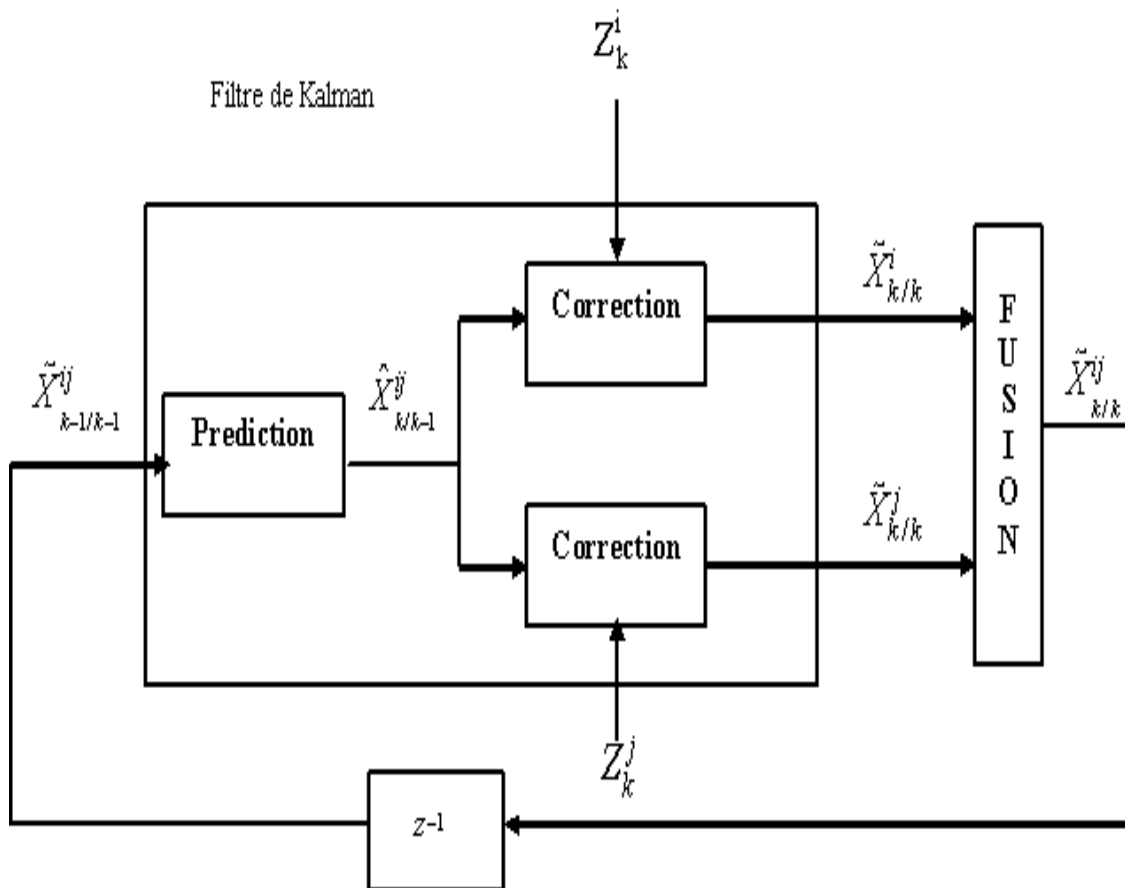


Figure 5.3 — Filtrage de Kalman bimode

Soit  $\tilde{X}_{k-1/k-1}^{12}$  l'état estimé fusionné. L'estimation a priori est donnée par :



$$\hat{X}_{k/k-1}^{12} = F \tilde{X}_{k-1/k-1}^{12}$$

L'estimation ainsi considérée est associée aux mesures  $Z_k^1$  et  $Z_k^2$  afin d'obtenir deux états estimés  $\tilde{X}_{k/k}^1$  et  $\tilde{X}_{k/k}^2$  en utilisant des filtres de Kalman locaux. Les équations de mesures sont calquées sur le modèle ci dessous :

$$Z_{k/k-1}^i = H^i \hat{X}_{k/k-1}^{12} + W_k^i, W_k^i \sim N(0, C_k^i)$$

où  $Z_{k/k-1}^i$  est le vecteur de mesure prédit,  $H^i$  la matrice reliant l'état à la mesure, et  $C_k^i$  la matrice de covariance de  $W_k^i$  pour le capteur  $i$ .

Pour chaque modalité on a classiquement l'estimation des vecteurs d'états :

$$\tilde{X}_{k/k}^i = \hat{X}_{k/k-1}^i + K_k^i [Z_k^i - Z_{k/k-1}^i]$$

où  $K_k^i$  est le gain de Kalman du filtre du capteur  $i$ .

Finalement, si le nouvel état estimé fusionné est donné par :

$$\tilde{X}_{k/k}^{12} = \tilde{X}_{k/k}^1 + [P_{k/k}^1 - P_{k/k}^{12}] [P_{k/k}^1 + P_{k/k}^2 - P_{k/k}^{12} - P_{k/k}^{21}]^{-1} (\tilde{X}_{k/k}^1 - \tilde{X}_{k/k}^2)$$

où  $P_{k/k}^1$  et  $P_{k/k}^2$  sont les matrices de covariance des estimés  $\tilde{X}_{k/k}^1$  et  $\tilde{X}_{k/k}^2$ .

$P_{k/k}^{12} = (P_{k/k}^{21})^t$  est la matrice de "cross-covariance" de  $\tilde{X}_{k/k}^1$  et  $\tilde{X}_{k/k}^2$ . La matrice de covariance de l'état estimé est donnée par :

$$P_{k/k}^{12} = P_{k/k}^1 - [P_{k/k}^1 - P_{k/k}^{12}] [P_{k/k}^1 + P_{k/k}^2 - P_{k/k}^{12} - P_{k/k}^{21}]^{-1} [P_{k/k}^1 - P_{k/k}^2]^t$$

On détaille ci-dessous l'algorithme de fusion :

$$\begin{aligned}
\tilde{X}_{0/0}^{12} &= X_0 \\
\hat{X}_{k/k-1}^{12} &= F \tilde{X}_{k-1/k-1}^{12} \\
\hat{Z}_{k/k-1}^1 &= H_k^1 \hat{X}_{k/k-1}^{12} \\
\hat{Z}_{k/k-1}^2 &= H^2 \hat{X}_{k/k-1}^{12} \\
\tilde{X}_{k/k}^1 &= \hat{X}_{k/k-1}^1 + K_k^1 [Z_k^1 - \hat{Z}_{k/k-1}^1] \\
\tilde{X}_{k/k}^2 &= \hat{X}_{k/k-1}^2 + K_k^2 [Z_k^2 - \hat{Z}_{k/k-1}^2] \\
\tilde{X}_{k/k}^{12} &= \tilde{X}_{k/k}^1 + [\tilde{P}_{k/k}^1 - \tilde{P}_{k/k}^{12}] [\tilde{P}_{k/k}^1 + \tilde{P}_{k/k}^2 - \tilde{P}_{k/k}^{12} - \tilde{P}_{k/k}^{12}]^{-1} (\tilde{X}_{k/k}^1 - \tilde{X}_{k/k}^2) \\
\tilde{P}_{0/0}^{12} &= P_0 \\
\hat{P}_{k/k-1}^{12} &= F \tilde{P}_{k-1/k-1}^{12} F^t + G Q G^t \\
K_k^1 &= \hat{P}_{k/k-1}^{12} (H_k^1)^t [H_k^1 \hat{P}_{k/k-1}^{12} (H_k^{rad})^t + R_k^1]^{-1} \\
K_k^2 &= \hat{P}_{k/k-1}^{12} (H^2)^t [H^2 \hat{P}_{k/k-1}^{12} (H^2)^t + R_k^2]^{-1} \\
\tilde{P}_{k/k}^1 &= [I - K_k^1 H_k^1] \hat{P}_{k/k-1}^{12} \\
\tilde{P}_{k/k}^2 &= [I - K_k^2 H^2] \hat{P}_{k/k-1}^{12} \\
\tilde{P}_{k/k}^{12} &= \left( \tilde{P}_{k/k}^{21} \right)^t = [I - K_k^1 H_k^1] \hat{P}_{k/k-1}^{12} [I - K_k^2 H^2]^T \\
\tilde{P}_{k/k}^{12} &= \tilde{P}_{k/k}^1 - [\tilde{P}_{k/k}^1 - \tilde{P}_{k/k}^{12}] [\tilde{P}_{k/k}^1 + \tilde{P}_{k/k}^2 - \tilde{P}_{k/k}^{12} - \tilde{P}_{k/k}^{21}]^{-1} [\tilde{P}_{k/k}^1 - \tilde{P}_{k/k}^{12}]
\end{aligned}$$

### 5.4.2 Consolidation : filtre à particule

Notre méthode de fusion est basée sur le calcul de poids particulières à partir des mesures des différentes capteurs. Elle est illustrée figure 5.4 pour la fusion de deux pistages.

Soit le vecteur d'état  $X_{k/k}^{12} = (x^{12}, \dot{x}^{12}, y^{12}, \dot{y}^{12})^t$  dont les composantes sont les positions et vitesses relatives de l'obstacle à suivre. On introduit le modèle d'évolution suivant, qui est un modèle à vitesse constante :

$$X_{k/k-1}^{12} = F X_{k-1/k-1}^{12} + G V_k \quad (5.2)$$

où :

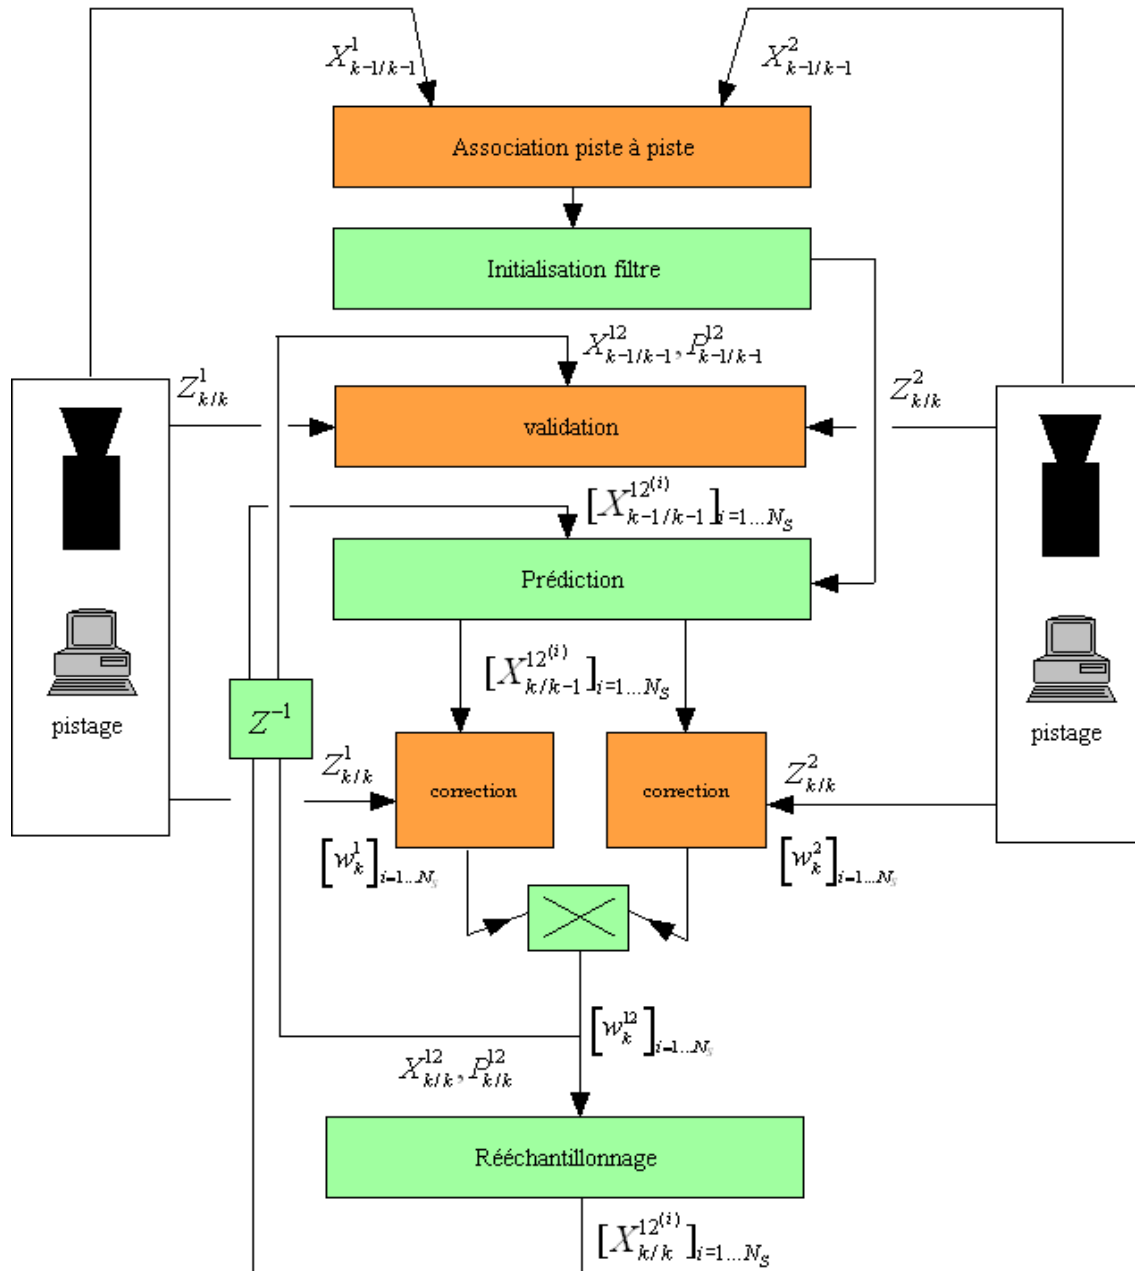


Figure 5.4 — Architecture de fusion / Filtrage particulaire

$$F = \begin{pmatrix} 1 & T & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad G = \begin{pmatrix} T^2/2 & 0 \\ T & 0 \\ 0 & T^2/2 \\ 0 & T \end{pmatrix}$$

et  $V_k$  le bruit sur l'état considéré comme l'accélération.

Quand deux pistes sont associées, on initialise un vecteur d'état fusionné : c'est la brique initialisation qui apparaît sur la figure 5.4. On pourra prendre la moyenne des estimations des deux pistages si les vecteurs d'états respectifs aux deux capteurs sont estimés dans le même référentiel. On pourra utiliser une partie de l'état fourni par un capteur et/ou l'autre pour compléter le vecteur d'état fusionné.  $X_{0/0}^{12} = (\frac{x^1+x^2}{2}, \frac{\dot{x}^1+\dot{x}^2}{2}, \frac{y^1+y^2}{2}, \frac{\dot{y}^1+\dot{y}^2}{2})^t$  est un des exemples de vecteur d'état initial fusionné. A partir de ce vecteur, un ensemble de  $N_s$  particules est construit. On génère des particules de bruit que l'on applique à notre vecteur initial :

$$X_{0/0}^{12(i)} = X_{0/0}^{12} + B_0^{(i)}, \forall i \in [1 \dots N_s] \quad (5.3)$$

On applique ensuite aux différentes particules le modèle définie en 5.2 : c'est la prédiction (mutation) des particules (voir figure 5.4). Pour cette mutation, on génère  $N_s$  particules de bruit et en appliquant le modèle défini en 5.2 on a :

$$X_{k/k-1}^{12(i)} = F X_{k-1/k-1}^{12(i)} + G V_{k-1}^{(i)}$$

La correction est effectuée au niveau du calcul des poids. Pour chaque capteur, on calcule  $N_s$  poids affectés au  $N_s$  particules prédites.

On a :

$$w_k^{1(i)} = p(Z_{k/k}^1 / X_{k/k-1}^{12(i)}) = p(Z_{k/k}^1 - H_k^1 X_{k/k-1}^{12(i)})$$

$$w_k^{2(i)} = p(Z_{k/k}^2 / X_{k/k-1}^{12(i)}) = p(Z_{k/k}^2 - H_k^2 X_{k/k-1}^{12(i)})$$

or  $p(Z_{k/k}^{12}/X_{k/k-1}^{12(i)}) = p(Z_{k/k}^1, Z_{k/k}^2/X_{k/k-1}^{12(i)}) = p(Z_{k/k}^1/X_{k/k-1}^{12(i)}) \cdot p(Z_{k/k}^2/X_{k/k-1}^{12(i)})$  donc

$$w_k^{12(i)} = w_k^{1(i)} * w_k^{2(i)}$$

On normalise ensuite les poids :

$$w_k^{12(i)} = \frac{w_k^{12(i)}}{\sum_{i=1}^{N_S} w_k^{12(i)}}$$

Finalement l'état estimé fusionné est donné par :

$$X_{k/k}^{12} = \sum_{i=1}^{N_S} w_k^{12(i)} \cdot X_{k/k-1}^{12(i)}$$

et sa covariance par :

$$P_{k/k}^{12} = \sum_{i=1}^{N_S} w_k^{12(i)} (X_{k/k}^{12(i)} - X_{k/k}^{12})(X_{k/k}^{12(i)} - X_{k/k}^{12})^T$$

Les particules sont rééchantillonnées et retournent à l'étape de prédiction si la validation à eu lieu. La méthode de validation est basée sur un test statistique.

### 5.4.3 Validation ou divergence bimode

Il faut vérifier qu'une piste bimode n'est pas entretenue de façon artificielle. Une façon de le vérifier est de tester la dissemblance entre les deux pistes capteurs la composant. Nous préférons ici vérifier que les mesures associées aux pistes sont toujours compatibles avec l'état estimé de la piste bimode.

Il faut s'interroger afin de déterminer si la nouvelle mesure contribue ou non à l'entretien du pistage bimode :

On a

$$p_k'^{12} = P_{k/k}^1 + P_{k/k}^2 - P_{k/k}^{12} - P_{k/k}^{21}$$

Pour chaque capteur la fenêtre de validation est définie par :

$$\left\{ Z_k^i, (Z_{k/k-1}^i - Z_k^i)^t S^{i-1} (Z_{k/k-1}^i - Z_k^i) \leq \gamma_i \right\}$$

où

$$S^{i-1} = H^i P_{k/k-1}^{i-1} H^{i-1} + C_k^i$$

et

$$P_{k/k-1}^{i-1} = F P_{k-1/k-1}^{i-1} F^t + G Q_k^i G^t$$

## 5.5 Application : suivi d'obstacle en virage par fusion d'estimations

On traite ici le scénario particulier du suivi de la cible en virage. Les observations capteurs sont traitées séparément par un module de pistage. On suppose ici que les estimations sont associées. La figure 5.5 représente la trajectoire réelle du véhicule. Les observations radar et lidar sont respective-




Figure 5.5 — La trajectoire réelle de la cible

ment représentées sur les figures 5.7 et 5.6. Les résultats des pistages mono capteur sont illustrés sur




Figure 5.6 — Les mesures laser bruitées




Figure 5.7 — Les mesures radar

la figure 5.8 pour le lidar, et sur la figure 5.9 pour le radar.

Le but de la fusion est ici d'estimer les caractéristiques cinématiques de la cible à la cadence du




Figure 5.8 — La trajectoire estimée par le traitement des mesures lidar

capteur le plus rapide (toutes les 8 ms) de la manière la plus robuste possible. On ne prend pas en compte ici la limite de portée des capteurs. On présente les résultats pour différentes méthodes de fusion exploitant les algorithmes présentés dans la section précédente. Pour la méthode de fusion, dite méthode (1), on n'utilise les données que quand elles sont disponibles. A contrario, la méthode de fusion (2) utilise une prédiction de la donnée du capteur le plus lent (lidar) à l'instant considéré par le capteur le plus rapide (radar). Les figures 5.13 et 5.14 illustrent la qualité de l'estimation. En effet, pour chaque composante du vecteur d'état, on remarque que la précision est bonne, quelque soit la méthode de fusion envisagée. Pour limiter les calculs, on préférera utiliser la méthode (1) pour l'implantation de l'algorithme dans le véhicule. La figure 5.12 montre les trajectoires estimées à partir des deux méthodes de fusion. Pour comparaison, on montre les résultats obtenus en utilisant un filtrage particulier à partir de la méthode de fusion (1). Les figures 5.13 et 5.14 permettent la comparaison entre la méthode utilisant le filtre de Kalman étendu et celle utilisant le filtrage particulier. Même si






Figure 5.9 — Les estimations sur  $r$  et  $\dot{r}$  à partir du traitement des mesures radar




Figure 5.10 — Erreur d'estimation sur  $x$  et  $\dot{x}$




Figure 5.11 — Erreur d'estimation sur  $y$  et  $\dot{y}$

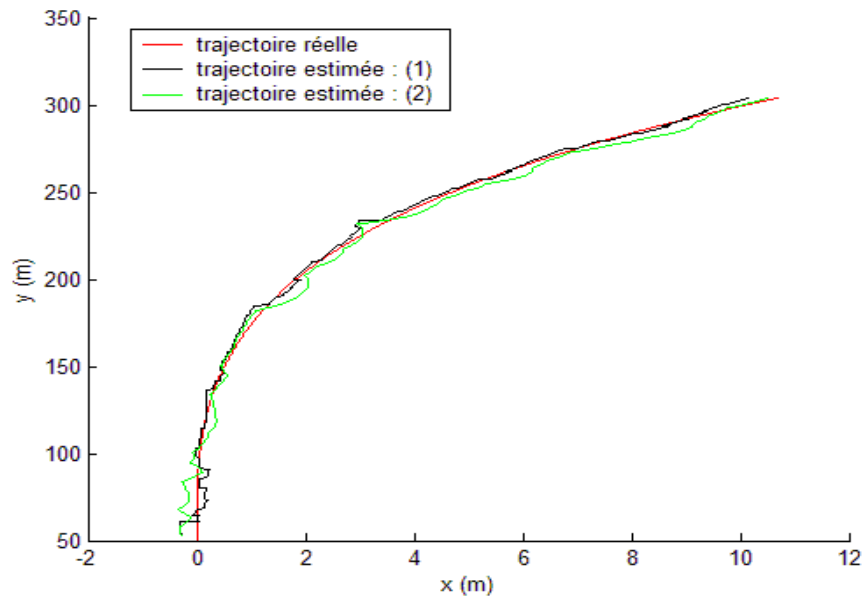


Figure 5.12 — Les trajectoires estimées selon la méthode de fusion envisagée

l'erreur semble un peu plus faible pour la méthode particulière, on peut conclure que les différentes démarches utilisées sont équivalentes.




Figure 5.13 — Erreur d'estimation sur  $x$  et  $\dot{x}$  : filtrage particulaire (PF) + EKF

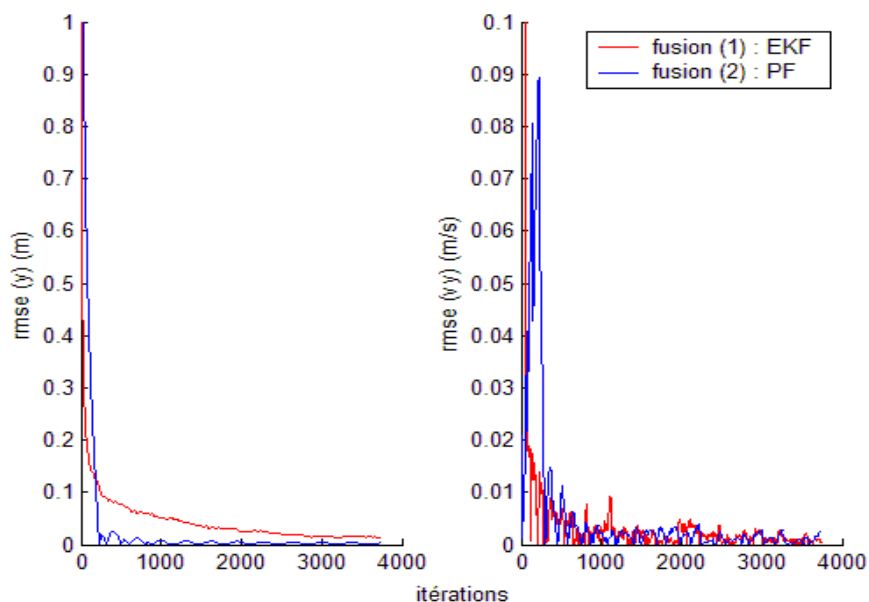


Figure 5.14 — Erreur d'estimation sur  $y$  et  $\dot{y}$  : filtrage particulaire (PF) + EKF

On a montré ici, la capacité de notre système à estimer précisément les caractéristiques cinématiques de l'obstacle dans un contexte de suivi en virage. Ici, aucune hypothèse n'est nécessaire afin d'accroître la précision des résultats. On accède toutes les 8 ms à la caractérisation précise de notre obstacle en terme de position et de vitesse. Le but recherché, exploiter de manière robuste et précise les données capteur afin d'accroître la reconnaissance de l'environnement en terme d'obstacles, est atteint. Tous les résultats présentés ci-avant sont issus de simulation. Ces dernières nous ont permis de vérifier la robustesse de nos différentes méthodes. Ces techniques sont pour la plupart implémentées dans VELAC et permettent une estimation précise de l'état des obstacles comme le présente le chapitre suivant.



## Chapitre 6

# RESULTATS EXPERIMENTAUX

### 6.1 Suivi d'obstacles

#### 6.1.1 Suivi d'obstacles par Lidar

On rappelle que la détection d'obstacles par Lidar délivre pour chaque obstacle, les coordonnées 3D  $(x, y, z)$  de celui-ci dans le repère du capteur ainsi que sa taille donnée par sa hauteur et sa largeur. Après ces différentes détections, il est nécessaire de les pister afin d'en extraire des informations importantes qui seront les caractéristiques cinématiques de l'obstacle : sa position et sa vitesse relatives  $(x, \dot{x}, y, \dot{y}, z, \dot{z})$ . On suppose ici qu'un obstacle devient une piste si sa variation de vitesse (donnée par la position du centre de la cible dans trois images consécutives) est inférieure à un seuil et si de plus sa taille est stable à une constante près dans trois images consécutives. Les seuils sur les vitesses pourront être fixés par les vitesses maximales relatives suivant les trois axes dans un contexte autoroutier. Par exemple, pour un obstacle fixe ayant comme vitesse relative  $-130 \text{ km/h}$ , on a une différence d'environ  $22 \text{ m}$  en distance relative entre deux instants d'acquisition.

Quand les obstacles sortent du champ de vue du capteur, ou sont occultés, l'algorithme utilise une approche basée sur l'âge de la piste : les paramètres de l'obstacle sont mis à jour par la prédiction de l'état, l'obstacle peut donc être associé de nouveau quand il réapparaît. La piste est dite morte si elle ne réapparaît pas après un temps fixé (proche de une seconde).

On a vu qu'il existait de nombreux critères dans la littérature pour prendre la décision d'associer un

obstacle à une piste. Ces critères dépendent essentiellement de la complexité de la tâche du pistage, comme par exemple le nombre de cibles, les manoeuvres effectuées par les obstacles, le nombre de fausses alarmes. On a vu que les méthodes à hypothèse unique sont adaptées aux environnements contenant peu d'événements [55]. On utilisera donc une méthode de ce type puisque dans un contexte autoroutier le nombre d'obstacles visibles à l'avant du véhicule est réduit, les manoeuvres effectuées par les obstacles sont très limitées : en particulier du fait qu'il n'y a pas de croisement. De plus, l'algorithme de détection d'obstacles par Lidar permet l'élimination de la plupart des fausses alarmes et délivre des mesures 3D précises. On utilisera donc une méthode d'association basée sur la recherche du plus proche voisin.

Pour l'estimation des pistes, considérons le modèle d'évolution linéaire à vitesse constante suivant :

$$X_{k+1/k} = FX_{k/k} + GV_k \quad (6.1)$$

où  $X_{k/k} = (x, \dot{x}, y, \dot{y}, z, \dot{z})^t$  est le vecteur d'état,  $F$  la matrice de transition qui modélise l'évolution de  $X_{k/k}$ , et  $V_k$  le bruit sur l'état considéré comme étant l'accélération.

$$F = \begin{pmatrix} 1 & T & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & T & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & T \\ 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix} \quad G = \begin{pmatrix} T^2/2 & 0 & 0 \\ T & 0 & 0 \\ 0 & T^2/2 & 0 \\ 0 & T & 0 \\ 0 & 0 & T^2/2 \\ 0 & 0 & T \end{pmatrix}$$

Le but du filtrage est d'estimer récursivement  $X_k$  à partir des observations dont le modèle linéaire est donnée ci-dessous :

$$Z_k = HX_{k+1/k} + W_k \quad (6.2)$$

où  $Z_k = (x, y, z)$  est l'observation,  $H$  la matrice d'observation, et  $W_k$  le bruit sur les mesures.

$$H = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix}$$

Si on considère les bruits indépendants et gaussiens i.e.  $V_k \sim N(0, Q_k)$  et  $W_k \sim N(0, C_k)$ , on peut appliquer les équations de Kalman [58] qui permettent d'estimer  $X_k$  de façon optimale.

Afin d'implémenter une estimation d'état par filtrage de Kalman, plusieurs éléments ont besoin d'être connus : les matrices de covariances sur les bruits de mesure  $C_k$  et  $Q_k$  et les conditions initiales  $X_0$  et  $P_0$ . La matrice  $R$  est donnée par les caractéristiques fournies par le constructeur et dépend de la mesure. En effet, le lidar délivre les coordonnées sphériques d'un impact et non pas ses coordonnées cartésiennes. Les erreurs sur les coordonnées sphériques sont fournies par le constructeur :  $\sigma_\rho = 5$  cm,  $\sigma_\theta = 0,036^\circ$   $\sigma_\phi = 0,018^\circ$ . On a de plus :

$$\begin{cases} x = \rho \cos \theta \\ y = \rho \sin \theta \sin \phi + x_e \sin \phi - y_e \cos \phi \\ z = -\rho \sin \theta \cos \phi - x_e \cos \phi - y_e \sin \phi \end{cases}$$

où  $x_e = y_e = 25$  mm représente le décalage de l'origine de la mesure laser et du repère capteur. La matrice  $R$  nous est donnée par :

$$C_k = \begin{pmatrix} \sigma_x^2 & \sigma_{xy}^2 & \sigma_{xz}^2 \\ \sigma_{xy}^2 & \sigma_y^2 & \sigma_{yz}^2 \\ \sigma_{xz}^2 & \sigma_{yz}^2 & \sigma_z^2 \end{pmatrix}$$

où les différents éléments de la matrice dépendent des mesures et de leurs erreurs respectives. Pour la matrice  $Q_k$  si on suppose que les bruits sont décorrélés sur chacun des trois axes, il vient :

$$Q_k = \begin{pmatrix} \sigma_{a_x}^2 & 0 & 0 \\ 0 & \sigma_{a_y}^2 & 0 \\ 0 & 0 & \sigma_{a_z}^2 \end{pmatrix}$$

Les valeurs des éléments diagonaux de  $Q_k$  sont choisies en fonction de l'application. Dans notre



contexte, l'accélération maximale possible obtenue lors d'un freinage avec un système A.B.S est fixée  $\sigma_{a_y} = 7 \text{ m/s}^2$ . Les valeurs sur les autres axes ne sont pas connues de façon précise, mais on peut les supposer plus faibles. On choisit  $\sigma_{a_x} = 3 \text{ m/s}^2$  et  $\sigma_{a_z} = 1 \text{ m/s}^2$ . Après avoir initialiser une piste, les composantes du vecteur d'état initial représentant la position sont fixées par l'observation initiale de la cible. Les composantes de vitesses sont fixées à 0. Du côté de la covariance, on l'initialise par rapport aux écarts maximums possibles. Le tableau 6.1 résume le choix des conditions initiales.

Composantes	$X_0$	$P_0$
$x$	$x_0$	15 m
$y$	$y_0$	100 m
$z$	$z_0$	10 m
$v_x$	0	50 km/h
$v_y$	0	130 km/h
$v_z$	0	20 km/h

Tableau 6.1 — Choix des conditions initiales

L'initialisation des différents paramètres permet donc au filtre de Kalman d'estimer récursivement de façon optimale l'état de l'obstacle. Des résultats sont présentés sur les figures 6.1, 6.2 et 6.3. Pour comparaison, on peut estimer l'état grâce aux méthodes particulières. On utilisera un algorithme de type SIR décrit dans le paragraphe 4.1.3. On décrit ici les différentes étapes du filtrage particulière pour notre application Lidar.

- Un jeu de  $N$  particules est généré à partir de la valeur initiale du vecteur d'état  $X_0$  défini dans le tableau 6.1. Chaque particule  $n \in [1, \dots, N]$  a un poids égal à l'inverse du nombre de particules (i).

$$X_0^n(i, i) = \sqrt{P_0(i, i)} * \text{random}()$$

$$w_0^n = \frac{1}{N}$$

- Le modèle d'évolution 6.1 est appliqué à chaque particule. Une prédiction de l'état de chaque particule est alors calculée (ii) :

On génère un bruit aléatoire :  $V = \sqrt{Q} * random()$

et il vient :

$$X_{k+1/k}^n = F X_{k/k}^n + V$$

- Le poids associé à chaque particule est calculé en fonction de l'observation issue de l'association de données (iii). Si on suppose que l'innovation donnée par  $Z_k - H X_{k+1/k}^n$  suit une loi uniforme alors :

$$w_k^n = p(Z_k - H X_{k+1/k}^n) = e^{-\frac{d_k^n}{2}}$$

où  $S_k$  est la covariance de l'innovation et  $d_k^n = (Z_k - H X_{k+1/k}^n)^t S_k^{-1} (Z_k - H X_{k+1/k}^n)$ . Chaque poids est ensuite normalisé :  $w_k^n = \frac{w_k^n}{\sum_{n=1}^N w_k^n}$ .

- On tire (avec remplacement)  $N$  particules parmi le jeu courant, de façon à favoriser les particules de plus forte vraisemblance (de plus fort poids). Le poids associé à chaque particule est de nouveau égal à l'inverse du nombre de particules (iv).
- L'espérance du jeu de particules fournit une estimation de l'état et de sa covariance :

$$X_{k/k} = \sum_{n=1}^N w_k^n X_{k+1/k}^n$$

$$P_{k/k} = \sum_{n=1}^N w_k^n (X_{k+1/k}^n - X_{k/k})(X_{k+1/k}^n - X_{k/k})^t$$

- Bouclage à l'étape (ii).

### 6.1.1.1 Résultats

Les premiers résultats présentent une séquence de suivi par filtrage de Kalman et par filtrage particulaire dans un cas mono cible dans des conditions réelles de circulation.

Les figures représentent respectivement la position latérale (figure 6.1), la position longitudinale (figure 6.2) et la vitesse radiale (figure 6.3) pour les deux types de filtres. Les mesures de position issues du traitement des données laser apparaissent en noir. La figure 25 permet de repérer cinq instants de la séquence (a,b,c,d,e). Au vu de ces résultats, les deux filtres donnent les mêmes

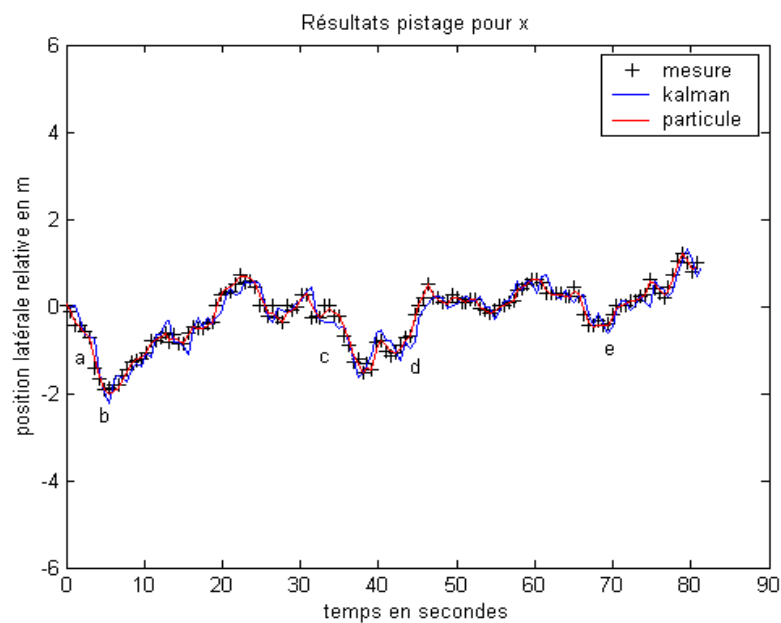


Figure 6.1 — Résultats du pistage en x dans un cas mono cible

estimées en position (voir figure 6.1 et 6.2). En effet, le modèle étant linéaire et les bruits gaussiens, l'utilisation du filtre de Kalman est optimale pour les estimées en position. L'intérêt de l'utilisation du filtre à particules est souligné par les résultats sur l'estimation de la vitesse radiale. On remarque que le filtrage particulaire permet une estimation de cette vitesse plus lissée que l'estimation par filtrage de Kalman (voir figure 6.3).

Pour les résultats suivants, dans un cas multicibles, on ne présentera que les estimées du filtre de Kalman pour une compréhension plus nette des figures. Dans les figures ci-dessous, les estimées en position et en vitesse des différentes pistes sont représentées avec des couleurs différentes (figures

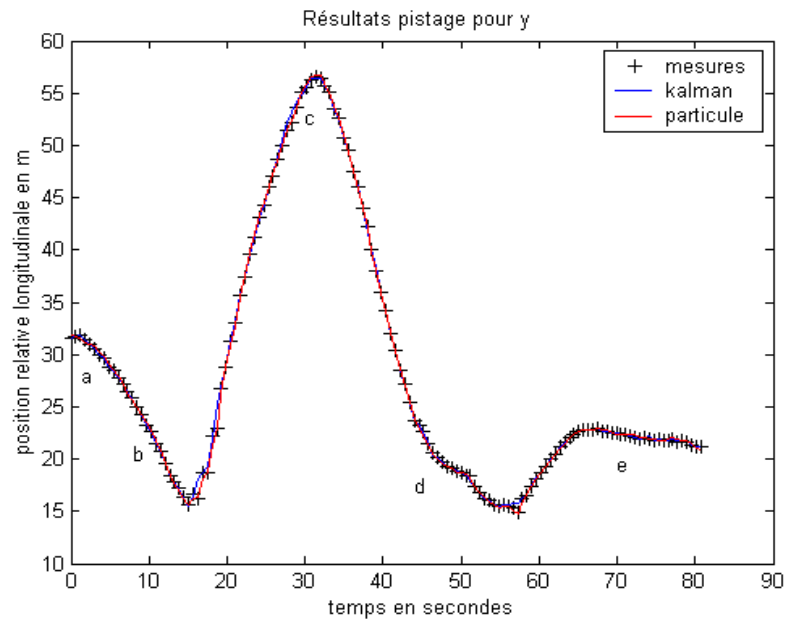


Figure 6.2 — Résultats du pistage en y dans un cas mono cible

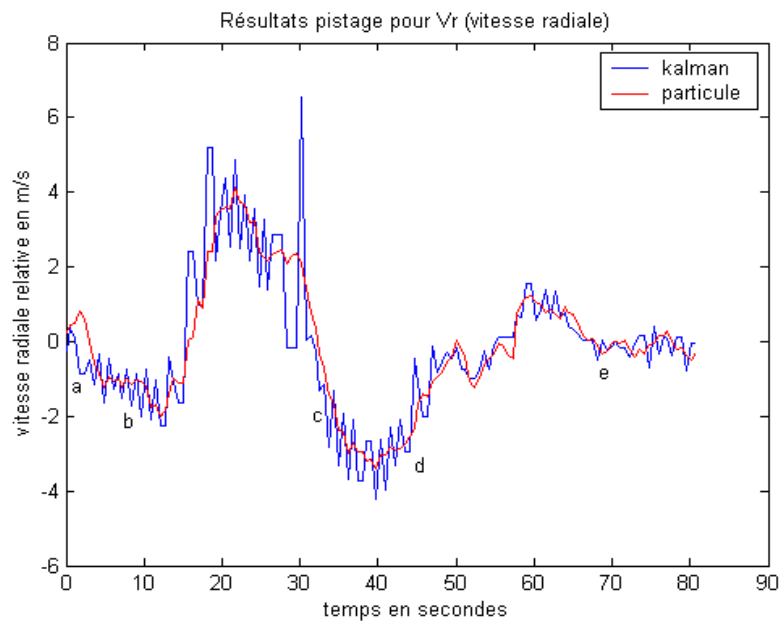




Figure 6.3 — Résultats du pistage pour  $V_r$  dans un cas mono cible



**Figure 6.4** — Instants a,b et c de la séquence



**Figure 6.5** — Instants d et e de la séquence

6.6, 6.7, 6.8). La figure 6.9 permet de repérer plusieurs instants de la séquence.

Ces résultats montrent la capacité du système de pistage multicibles dans un contexte autoroutier. On remarque que l'on est capable de détecter et pister plusieurs types d'obstacles (voitures et camions). Le système d'association de données basé sur la recherche du plus proche voisin semble suffisant pour ce système. En effet, on remarque ici qu'il n'apparaît aucune fausse piste. De plus, la précision sur les mesures Lidar permet à l'association de données d'intégrer facilement l'observation qui correspond le mieux à la piste considérée. On pourra, par exemple, utiliser la taille de l'obstacle comme un des critères d'associations au cas où plusieurs mesures tombent dans la fenêtre de validation. De plus, dans un contexte routier, le nombre de pistes à suivre à l'avant d'un véhicule est faible ce qui réduit considérablement les calculs nécessaires aux systèmes d'association.

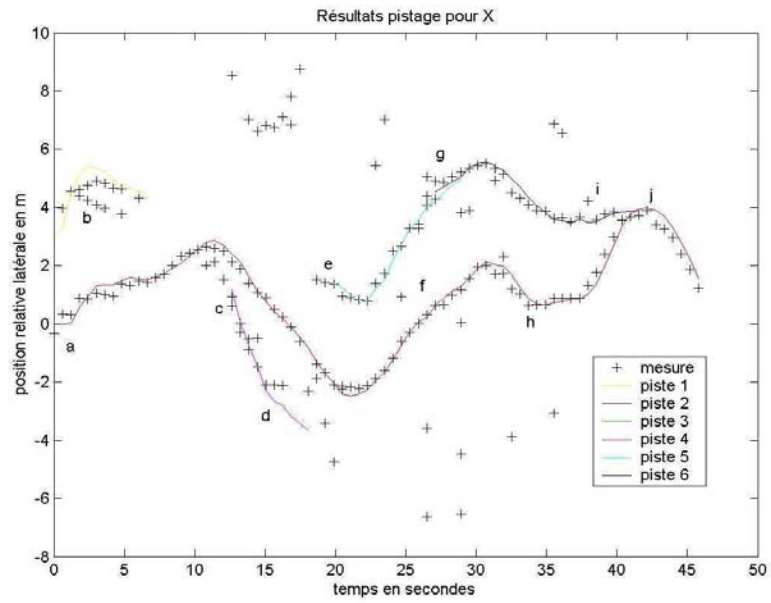


Figure 6.6 — Résultats pistage pour  $x$  dans un cas multicibles




Figure 6.7 — Résultats pistage pour  $y$  dans un cas multicibles cible




Figure 6.8 — Résultats pistage pour  $V_r$  dans un cas multicibles




Figure 6.9 — Instants a,b,c,d,e,f,g,h,i et j de la séquence



### 6.1.2 Suivi d'obstacles par Radar

Le second type de données utilisé pour le pistage est donc issu du Radar PAROTO. On rappelle que le capteur Radar à onde millimétrique permet de délivrer toutes les 8 ms un indice de porte distance  $P$  de largeur 22,5 m et un indice vitesse  $Ind_{vit}$  de largeur 0,238 m/s pour chaque obstacle dont l'amplitude de la transformée de Fourier du signal réfléchi est supérieure à un seuil fixé expérimentalement. L'indice de porte distance correspond à la distance radiale  $R$ . La mesure de distance sera calculée par  $R(m) = (P - 1) * 22,5 + 11,25$  et la mesure de vitesse radiale relative par  $\dot{R}(m/s) = (Ind_{vit} - 1 - \frac{N}{2}) * 0,238$ .

Le radar ne fournit pas les mêmes observations que le Lidar. Il n'est pas possible de connaître la taille de la cible sélectionnée. En revanche, le nombre de détection est supérieur, mais il n'est pas possible de caractériser les différentes cibles détectées. On ne pourra donc pas différencier facilement une voiture d'un pont, si le radar est le seul capteur utilisé. Cependant, ce capteur est capable de fournir une mesure de distance et une mesure précise de vitesse radiale relative, toutes les 8 ms à des distances pouvant atteindre 200 m dans toutes les conditions météorologiques. On s'attachera donc ici à estimer  $X_k = (R, \dot{R})^t$  à partir des mesures afin d'obtenir un estimé plus précis en distance que la mesure issue de l'intervalle de confiance de 22,5 m.

Pour initialiser les pistes à envoyer au système de filtrage on utilise une méthode basée sur des hypothèses multiples. En effet, le nombre de fausses détections n'étant plus négligeable, il est nécessaire de les prendre en compte. La brique d'initialisation fournit donc au système de pistage des pistes que l'on qualifiera de tentées. Le système ne valide les pistes tentées que si des observations lui sont associées à chaque instant d'acquisition pendant un laps de temps défini (une non association durant le laps de temps  $\delta t_{valid}$  ainsi considéré correspond à la non validation de la piste). Une piste validée sera dite morte si aucune observation n'apparaît pour la mise à jour pendant un temps  $\delta t_{fin}$ . On pourra fixer ces deux paramètres temporels en fonction de la distance de la cible considérée.

Le traitement du signal délivre les observations à incorporer à l'initialisation par paquet de  $L$  mesures.  $L$  n'est pas forcément constant et sera choisi de manière à éviter la multiplication des fausses pistes. En effet, des fausses mesures peuvent apparaître à des instants quelconques. Ces fausses mesures sont en général ponctuelles et ne peuvent initialiser une piste que si  $L$  est petit.  $L$  est fixé à 10 pour notre application, ce qui représente un temps de 80 ms. On va donc rechercher dans un arbre formé

par l'ensemble des mesures délivrées pendant  $LT_r$  ( $T_r = 8 \text{ ms}$ ), les séquences de mesures qui peuvent correspondre à des pistes tentées. Cette recherche est basée sur des hypothèses multiples. On aura comme hypothèse :

- la mesure provient d'une nouvelle piste
- la mesure est une fausse détection

L'hypothèse "la mesure provient d'une cible déjà existante" n'est pas considérée ici puisque la brique d'initialisation ne prend en entrée que les observations qui n'ont pas été associées. On sélectionnera les hypothèses les plus vraisemblables (dont la probabilité est supérieure à un seuil) afin de délivrer au système de filtrage les pistes tentées. Une piste tentée mais non validée sera dite morte.

Après la description de la gestion des pistes, on décrit ici le filtre de poursuite qui permet l'estimation de l'état de notre obstacle. On rappelle qu'un filtre est utilisé pour chaque piste. Le modèle d'évolution linéaire, choisi à vitesse constante, est défini par :

$$X_{k+1/k} = FX_{k/k} + GV_k \quad (6.3)$$

où

$$F = \begin{pmatrix} 1 & T_r \\ 0 & 1 \end{pmatrix} \quad G = \begin{pmatrix} T^2/2 \\ T \end{pmatrix}$$

Le but du filtrage est d'estimer  $X_k$  récursivement à partir des mesures  $Z_k$  dont le modèle de mesure linéaire est :

$$Z_k = HX_{k+1/k} + W_k \quad (6.4)$$

où

$$H = \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix}$$

On a vu que les bruits sur la mesure pouvaient être considérés comme approximativement gaussiens. Dans ce cas, le filtre de Kalman est optimal puisque le modèle de mesure est linéaire. On présente ici les matrices  $R$  et  $Q$  et les conditions initiales choisies. Comme pour le capteur Lidar, il est nécessaire de connaître les matrices  $R$  et  $Q$ . La matrice  $R$  est donnée par la définition 2.2 et on choisit la matrice  $Q$  qui sera composée d'un seul scalaire correspondant à l'accélération maximale obtenue lors d'un

freinage A.B.S. :  $\sigma_{a_R} = 7 \text{ m/s}^2$ . Le tableau 6.2 résume les conditions initiales choisies pour  $X_0$  et  $P_0$ .

Composantes	$X_0$	$P_0$
$R$	$R_0$	100 m
$\dot{R}$	$\dot{R}_0$	130 km/h

**Tableau 6.2** — Choix des conditions initiales pour le système radar

Les différentes étapes du système (association et filtrage multicibles) s'enchaînent ensuite séquentiellement selon les équations de Kalman.

### 6.1.2.1 Résultats

Le résultats présentés ci-dessous sont acquis dans des conditions réelles de circulation. On peut voir que l'on est capable de détecter et pister plusieurs types d'obstacles : moto (figure 6.10), piétons (figure 6.11), véhicules (figure 6.12). De plus, on est capable de pister plusieurs cibles (figure 6.12). Sur ces illustrations, nous montrons que le pistage fournit des estimations de distance de manière plus précise qu'une porte de largeur 22,5 m. Pour la vitesse, l'estimée correspond à la mesure. On peut également s'apercevoir que dès que l'estimée de vitesse devient positive alors l'obstacle commence effectivement à s'éloigner (figure 6.13). Sur la figure 6.11, même si le Radar ne fournit pas de mesures (la cible est sortie du champ de vue des capteurs), la position et la vitesse relative du piéton sont estimées. Cette estimation est valable pendant un laps de temps en utilisant une approche basée sur l'âge de la piste.




Figure 6.10 — moto




Figure 6.11 — piéton




Figure 6.12 — deux obstacles




Figure 6.13 — obstacle dans le brouillard

### 6.1.3 Conclusion

On a décrit ici deux systèmes de pistage différents basés sur les filtres de Kalman et les méthodes particulières. Le choix des méthodes d'association de données est fortement dépendant des capteurs et de l'environnement. On a montré qu'avec un capteur Lidar il était possible de détecter et de pister plusieurs cibles jusqu'à 100m. Cependant, la technologie de ce capteur ne lui permet pas de fonctionner de manière probante dans des conditions de brouillard. Le système radar est quant à lui capable de délivrer de manière précise la vitesse radiale relative des obstacles dans de nombreuses

conditions climatiques. Ce capteur peut détecter des obstacles jusqu'à 200 m. Cependant, il délivre parfois des fausses détections, qu'il n'est pas possible de filtrer. Ces détections peuvent provenir de panneaux de signalisation, de barrières de sécurité ou encore de pont. Pour palier ce problème, l'utilisation simultanée des deux capteurs, afin d'améliorer le système d'alerte, se fait de manière naturelle. Les deux systèmes vont donc être utilisés afin de prendre en compte de manière adéquate leurs complémentarités et redondances. La sortie de ce système de fusion sera plus robuste et pourra alerter le conducteur de manière fiable. Dans le cadre du projet PAROTO, l'utilisation de la méthode de pistage développée par SAGEM pour l'infrarouge remplace la méthode basée sur le télémètre laser.

## 6.2 Fusion de pistages

On a vu auparavant que les données radar sont complémentaires avec toutes les autres données. En effet, le Radar est insensible aux conditions atmosphériques, il est donc judicieux voir même indispensable d'utiliser un capteur de ce type pour la détection d'obstacles dans un environnement routier.

On présente ici différents résultats de fusion de pistages. Ces pistages sont des systèmes totalement indépendants. On détaillera ici la fusion de pistage IR et Radar et la fusion de pistage Lidar et Radar. Tous les résultats présentés sont issus de données acquises dans des conditions réelles de circulation. On s'attachera dans cette présentation à montrer l'apport de la fusion pour un système robuste de surveillance des obstacles sous de nombreuses conditions atmosphériques.

### 6.2.1 Calibrage et datation

Les entrées du module de fusion sont les pistes entretenues au niveau de chacun des capteurs. Dans cette section, nous présentons les repères utilisés. Du point de vue Radar, une piste sur un obstacle supposé est caractérisée par une distance et une vitesse radiale  $(r, \dot{r})$ , et par l'imprécision sur ces mesures. Pour le télémètre laser (respectivement la caméra infrarouge), une observation à un instant donné est un objet. Un objet est caractérisé par une position  $(x_{tel}, y_{tel})$  (respectivement  $(x_{ir}, y_{ir})$ ) mesurée relativement au capteur à un instant donné et par l'imprécision sur cette position. Une piste est un suivi de cet objet au cours du temps. La piste renseigne la position et la vitesse



estimées de cet objet.

Les données télémétriques (respectivement infrarouge) et radar ne sont pas données dans la même référence. On choisit donc le repère lié au radar comme repère pour la fusion. Les observations télémétriques (respectivement infrarouge) subissent donc une transformation avant l'entrée dans le module de fusion (voir figure 6.14) (respectivement figure 6.15). Les zones couvertes par les capteurs




Figure 6.14 — repères capteurs radar et laser




Figure 6.15 — repères capteurs radar et infrarouge

sont également définies dans le repère fusion (voir figures 6.16, 6.17). La zone exclusive télémètre (respectivement infrarouge) est la zone couverte par le seul capteur télémétrique (respectivement infrarouge). La zone exclusive Radar s'étend au-delà de la portée théorique du lidar (90 mètres) (respectivement 70 à 80 mètres pour l'infrarouge). L'analyse de ces zones par le module de fusion coïncide donc avec l'analyse des capteurs seuls. C'est dans la zone bimode que se situe le travail de fusion, puisqu'elle est couverte par les deux capteurs. Le système de datation des données s'appuie

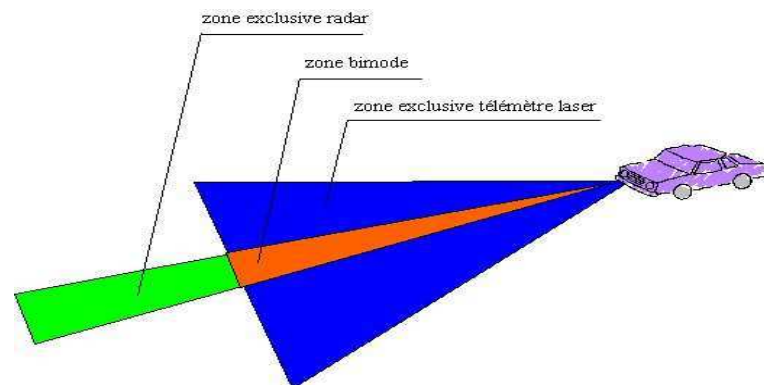


Figure 6.16 — zone de couverture des capteurs





Figure 6.17 — champ radar et ir

sur l'utilisation de l'horloge du bus IEEE 1394, qui à la particularité de donner une base de temps commune à tous les PC connectés.

## 6.2.2 Résultats

### 6.2.2.1 Radar+IR

Nous illustrons ici l'apport de la fusion des données dans l'interprétation de scènes typiques, et montrons le gain par rapport aux résultats obtenus par les traitements mono capteur.



La Figure 6.18 illustre une situation autoroutière simple. Nous voyons deux véhicules à l'image. Les pistes produites au niveau des capteurs sont reportées dans la figure du centre : les positions relatives des obstacles détectés sont symbolisées par des points, les erreurs associées par des ellipses. Comme attendu, les erreurs sur les mesures Infrarouge croissent avec la distance. De plus, "les distances Infrarouge" sont plus imprécises que les "distances Radar". Par contre, l'imprécision en direction est plus faible du côté Infrarouge. Le véhicule de gauche est dans la zone exclusive IR. La piste IR lui correspondant est donc produite par le module de fusion sans modification. Le véhicule circulant sur notre voie est détecté par les deux capteurs, les pistes IR et Radar sont suffisamment proches pour

être fusionnées. La piste bimode produite a une imprécision sur la position bien plus faible.




Figure 6.19 — Dépassement d'un véhicule, étape 1




Figure 6.20 — Dépassement d'un véhicule, étape 2

Ce cas illustre la complémentarité de la caméra Infrarouge et du Radar. Dans cette situation, on s'approche assez près du véhicule (figure 6.19) et on déboîte rapidement (figure 6.20, début de la manoeuvre). Le Radar seul détecte un obstacle qui se rapproche droit devant jusqu'au dernier mo-

ment. L'information de direction donnée par l'Infrarouge influence le pistage bimode, permettant la détection de la manoeuvre d'évitement. La situation vue par le système est donc moins alarmante que la situation vue par le Radar seul, dans ce cas.




Figure 6.21 — Détection Radar non confirmée par l'Infrarouge

Sur la figure 6.21, le véhicule à l'image est dans la zone exclusive IR, la piste IR correspondante est donc produite par le module de fusion. Le Radar génère une piste erronée à partir des échos sur la barrière de sécurité dans la zone de recouvrement des capteurs. Comment traiter une telle piste ? Faut-il la considérer comme une fausse alarme d'un capteur ou à une non détection de l'autre. La décision dépendra de la confiance que l'on met en les capteurs. Dans le cadre expérimental du projet PAROTO, on décide qu'une piste monomode dans le champ de recouvrement est une fausse alarme puisque le nombre de non détections observé est faible. Dans notre exemple, la piste non confirmée par l'Infrarouge est donc rejetée, évitant ainsi une possible alarme. Des situations symétriques (artefacts thermiques non confirmés par le Radar) se produisent également.

### 6.2.2.2 Radar+Lidar

Les deux premières figures correspondent aux résultats sur l'estimation de la position de la cible selon l'utilisation d'une combinaison à base de filtre de Kalman ou à base de méthode particulière.

Pour l'estimation de distance, le choix de la méthode n'est pas influent. En revanche, on remarque que les méthodes particulières permettent une estimation de  $x$  plus en conformité avec nos attentes qu'avec la méthode de Kalman. En effet, les estimations de  $x$  par le filtrage particulaire semblent converger plus rapidement vers la mesure tandis que pour le filtrage de Kalman l'estimation semble beaucoup plus bruitée. Dans la suite, on choisit donc de présenter les résultats donnés par le filtrage particulaire.




Figure 6.22 — Comparaison Kalman / Particule pour R




Figure 6.23 — Comparaison Kalman / Particule pour x

Les résultats présentés sont issus de données acquises dans des conditions réelles de circulation autoroutière en pleine journée (figure 6.24, figure 6.25, figure 6.26, figure 6.27, figure 6.28, figure 6.29, figure 6.30, figure 6.31, figure 6.32) ou durant la nuit (figure 6.33, figure 6.34).

Les résultats représentent le suivi d'une cible dans un contexte autoroutier. Pour les deux premiers scénarios (figure 6.24, figure 6.25, figure 6.26, figure 6.27, figure 6.28, figure 6.24, figure 6.30), on s'attache à représenter les résultats sur une séquence de 60 s pour le premier et d'environ 30 s pour le deuxième. On rappelle qu'une séquence de 60 s peut engendrer, si un seul obstacle est présent durant toute la durée du scénario, 7500 mesures radar (1 mesure toutes les 8 ms). Les résultats de fusion seront détaillés par une estimation de distance radiale, de vitesse radiale, et de cap relatifs. Les mesures Radar sont représentées en vert, celles du Lidar en bleu, et les résultats de fusion sont en rouge. Les autres figures (figure 6.31, figure 6.32, figure 6.33, figure 6.34) représentent une visualisation des résultats à des instants précis dans différents scénarios. Cette visualisation montre l'état de la piste et de ses particules associées.

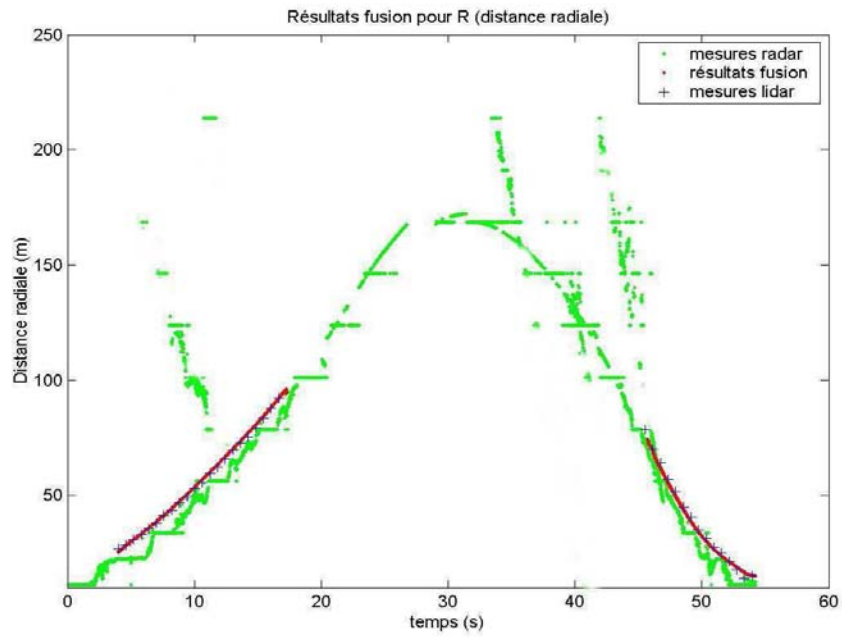


Figure 6.24 — Résultat fusion pour distance radiale relative (1)

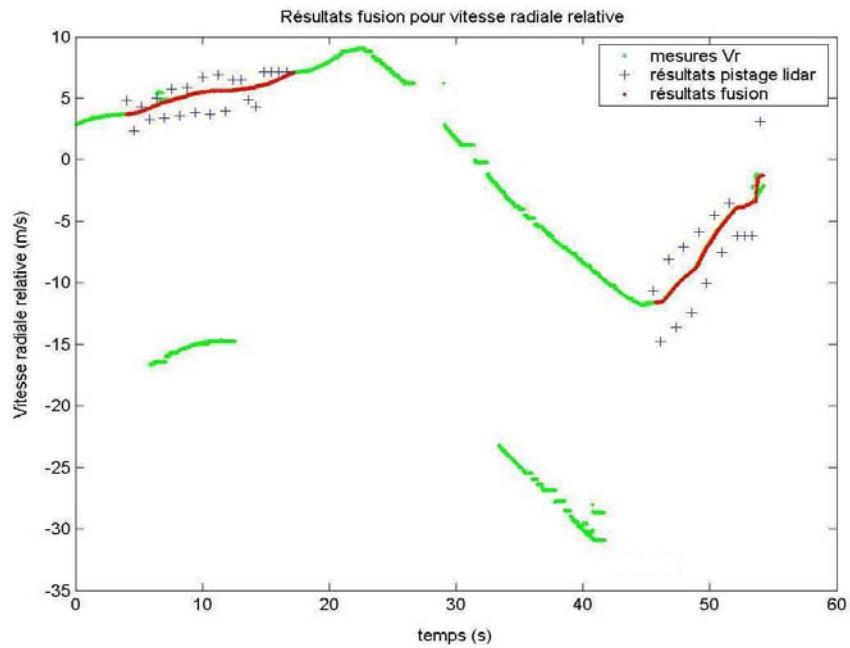


Figure 6.25 — Résultat fusion pour vitesse radiale relative (1)






Figure 6.26 — Résultat fusion pour cap relatif (1)



Figure 6.27 — Visualisation de la piste radar à 170m

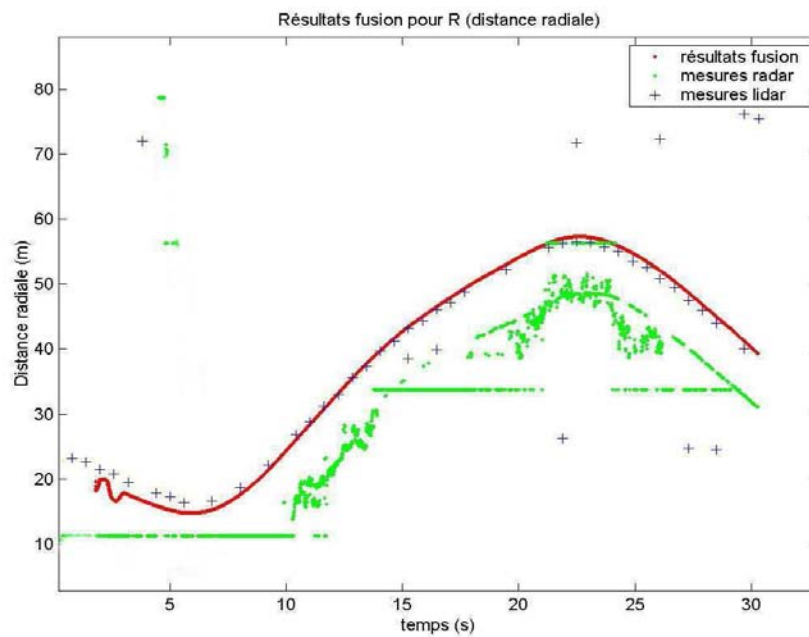


Figure 6.28 — Résultat fusion pour distance radiale relative (2)

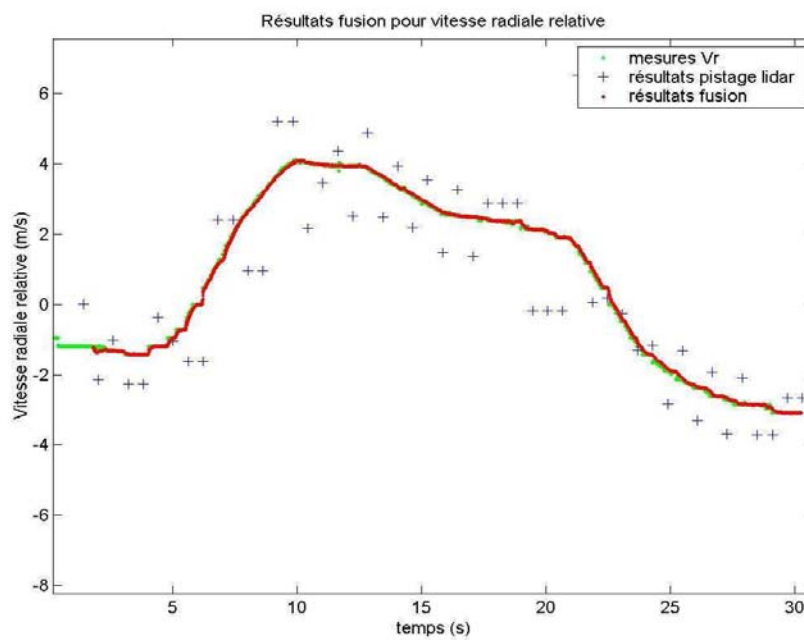


Figure 6.29 — Résultat fusion pour vitesse radiale relative (2)

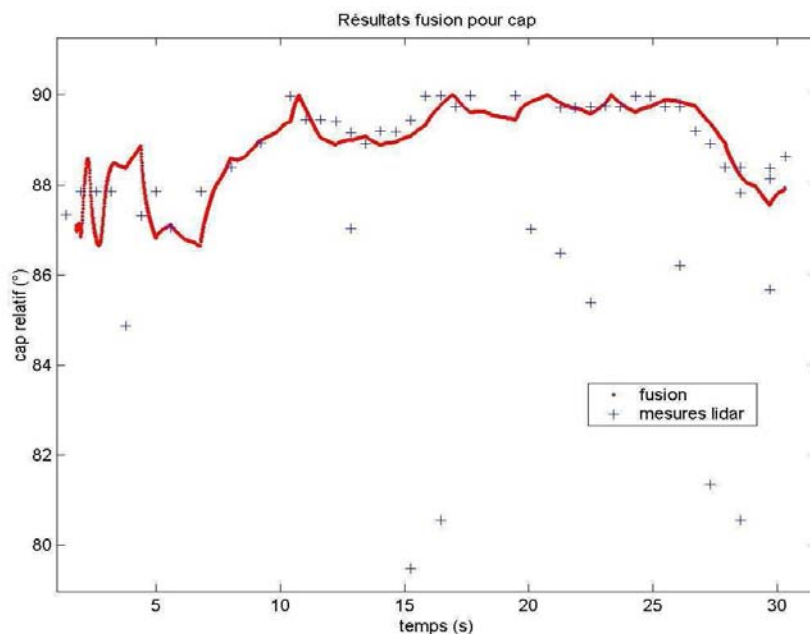


Figure 6.30 — Résultat fusion pour cap relatif (2)

Tout d'abord, on peut remarquer que le Radar est capable de détecter des obstacles jusqu'à 200 m tandis que la limite du Lidar est à un peu moins de 100 m (figure 6.24). De plus, on remarque sur les figures figure 6.24, figure 6.25, figure 6.28 qu'il existe des mesures Radar qui peuvent engendrer des fausses pistes Radar. Ces mesures radar sont en général issues d'objets fixes propres à un environnement autoroutier. On peut assimiler les fausses mesures radar à des barrières de sécurité, des ponts, des panneaux, des talus, ... Dans tous les scénarios étudiés, ces objets fixes engendrent des mesures qui réagissent de la même façon : la distance donnée diminue fortement en fonction d'une vitesse relative négative. Par exemple, on remarque quatre paquets de mesures susceptibles de procurer des fausses pistes radar sur la figure 6.24, et un seul paquet apparaît sur la figure 6.28. Les pistes Lidar et Radar ne sont pas représentées ici pour la clarté des résultats. Les pistes Radar, qui ne sont pas confirmées par une des pistes Lidar dans la zone de recouvrement ou bimode, sont donc considérées comme des fausses pistes. La fusion de ces deux pistages permet donc d'éliminer les fausses pistes données par le radar. Un des objectifs de la fusion qui consiste à éliminer les fausses pistes est donc rempli.

L'autre objectif est d'exploiter opportunément les complémentarités et redondances des deux pis-

tages. Une des complémentarités est temporelle. En effet, les données fusionnées sont délivrées toutes les 8 ms à la cadence des mesures radar. Les caractéristiques des pistes fusionnées correspondent à nos attentes. Effectivement, on remarque que la distance radiale de la piste bimode correspond à la distance radiale délivrée par le Lidar (beaucoup plus précis en distance que le Radar) et que la vitesse radiale correspond à celle du Radar (beaucoup plus précis que le Lidar). Sur la figure 6.28, les mesures de distances Radar connaissent un biais puisque ces mesures correspondent en fait à des mesures de portes de largeur 22,5 m. Par exemple, pour une détection dans la porte 1 la mesure sera de 11,25m ( 11,25 m) : on ne sait pas précisément où on se trouve. L'estimation de distance fusionnée suit alors la mesure délivrée par le lidar puisque cette mesure est beaucoup plus précise que celle donnée par le radar. Enfin, pour exploiter les caractéristiques latérales données par le télémètre laser (complémentaire au radar), on représente le cap des pistes suivies fusionnées (figure 6.26 et figure 6.30) donnée toutes les 8 ms.

On représente maintenant la visualisation des résultats à des instants précis pour des scénarios donnés. La figure 6.31 propose une explication des différentes fenêtres de visualisation. Ces fenêtres exposent principalement les résultats respectifs aux deux capteurs utilisés et les résultats de la fusion (cercle jaune) en affichant l'état des différentes particules. Une représentation 3D et une visualisation de la scène sont de plus disponibles. L'initialisation des particules est illustrée sur les figure 6.31 et figure 6.32. Les particules, représentées par des points jaunes, sont générées normalement à partir de l'état initial de la piste et de sa covariance. A l'instant initial, on constate que les particules occupent un espace assez vaste tant en position qu'en vitesse. Ces particules se regroupent ensuite autour de l'estimation (figure 6.32 et figure 6.34) à partir du rééchantillonnage. Sur les figures figure 6.31 et figure 6.32 et figure 6.33, des véhicules, étant dans une zone exclusive monomode, sont détectés par le télémètre. Ces pistages ne nécessitent donc aucune confirmation par le radar. Symétriquement, des pistages radar ne requièrent aucune corroboration du lidar (figure 6.33).

Le cas du dépassement d'un obstacle (figure 6.32) illustre la complémentarité du lidar et du radar. Avec le radar seul, le système détecte un véhicule s'approchant jusqu'au dernier moment. La direction de détection du lidar influence la piste bimode, détectant ainsi la dérive du véhicule. Cette piste ne pourra donc pas être classifiée comme une menace potentielle même si elle est proche et sa vitesse relative est négative. De la même façon, la figure 6.33 représente l'insertion d'un obstacle dans notre voie de circulation. La piste est initialisée dès qu'elle est visible par le radar et la détection

lidar permettra de savoir si l'obstacle s'insère ou si il vient juste d'apparaître. Enfin, la figure 6.34 illustre l'utilisation de ce type de capteur dans des conditions de nuit. On remarque que notre système est capable de détecter des obstacles même si ils sont difficilement visibles (caméra vidéo). L'utilisation de capteurs vidéo ne serait donc pas adéquate dans ce scénario.

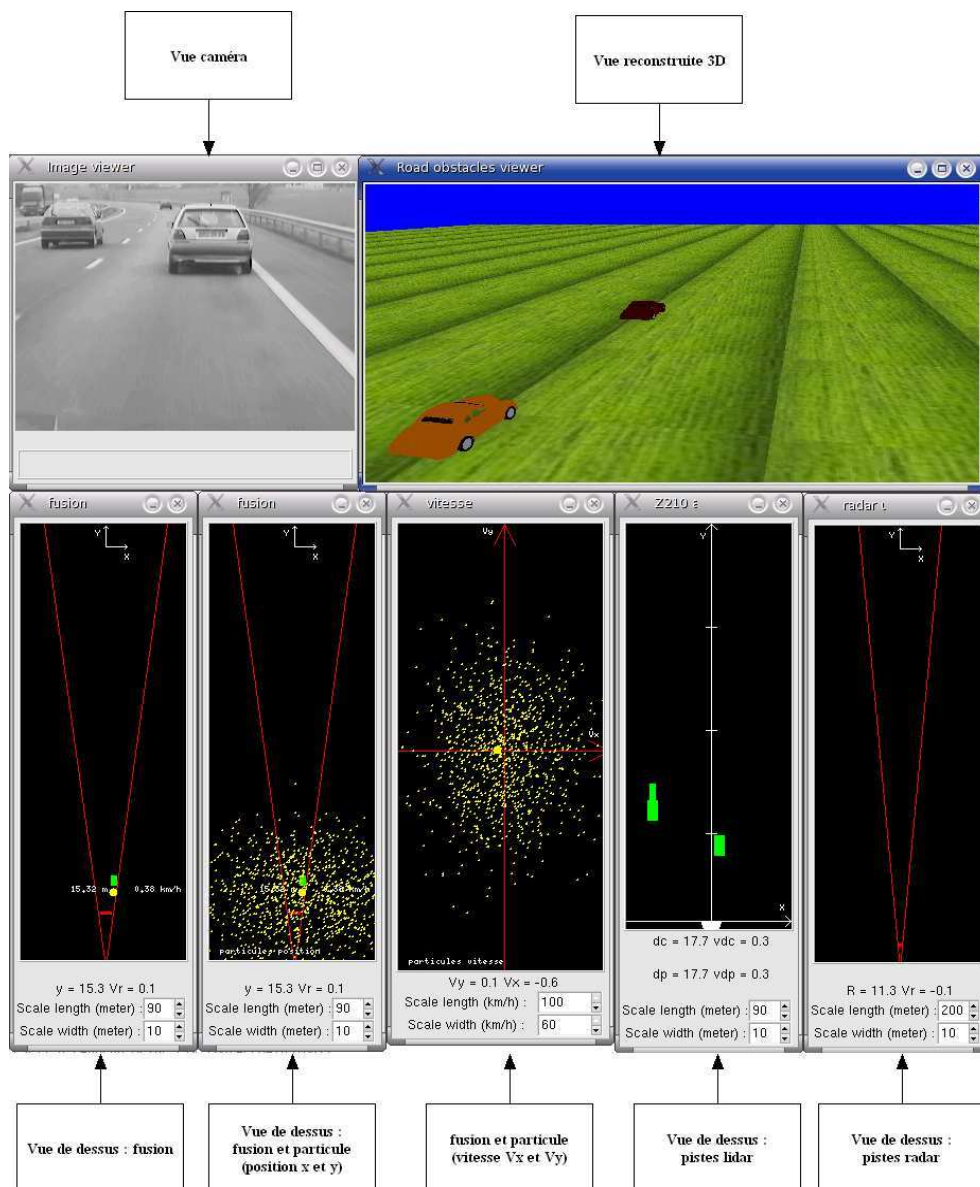


Figure 6.31 — Représentation des résultats (initialisation d'une piste bimode)

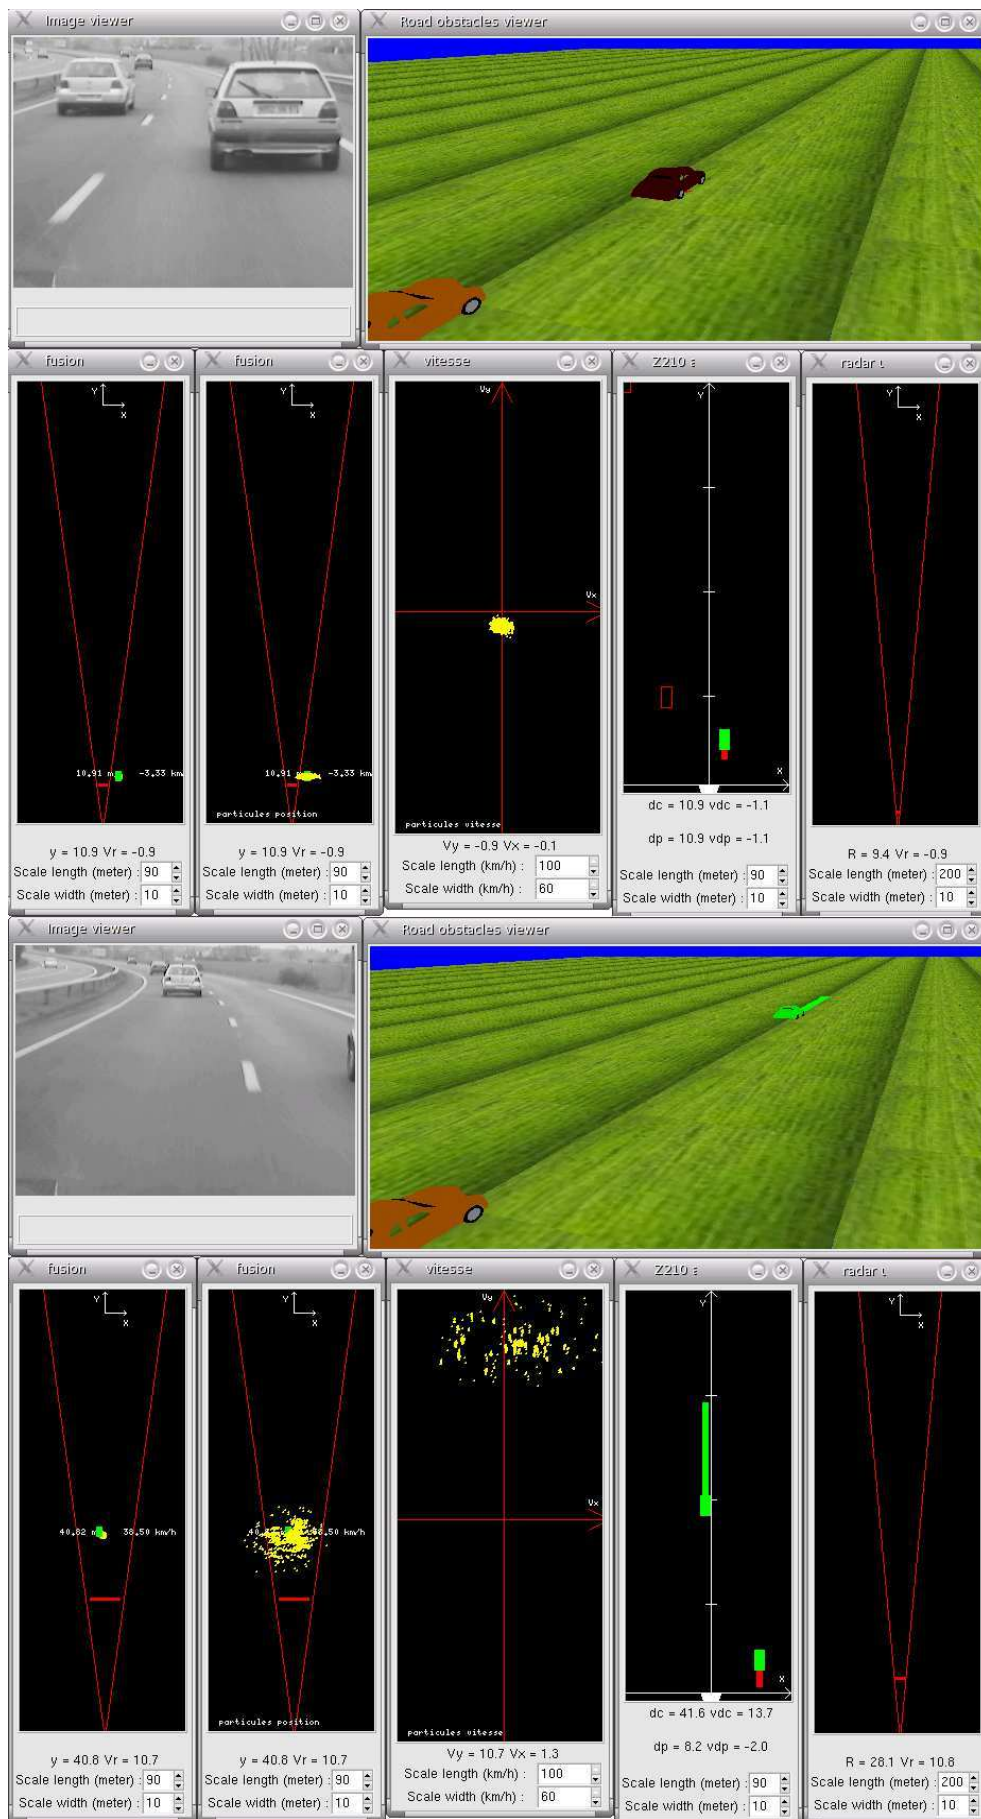


Figure 6.32 — Représentation des résultats (dépassement d'un véhicule)



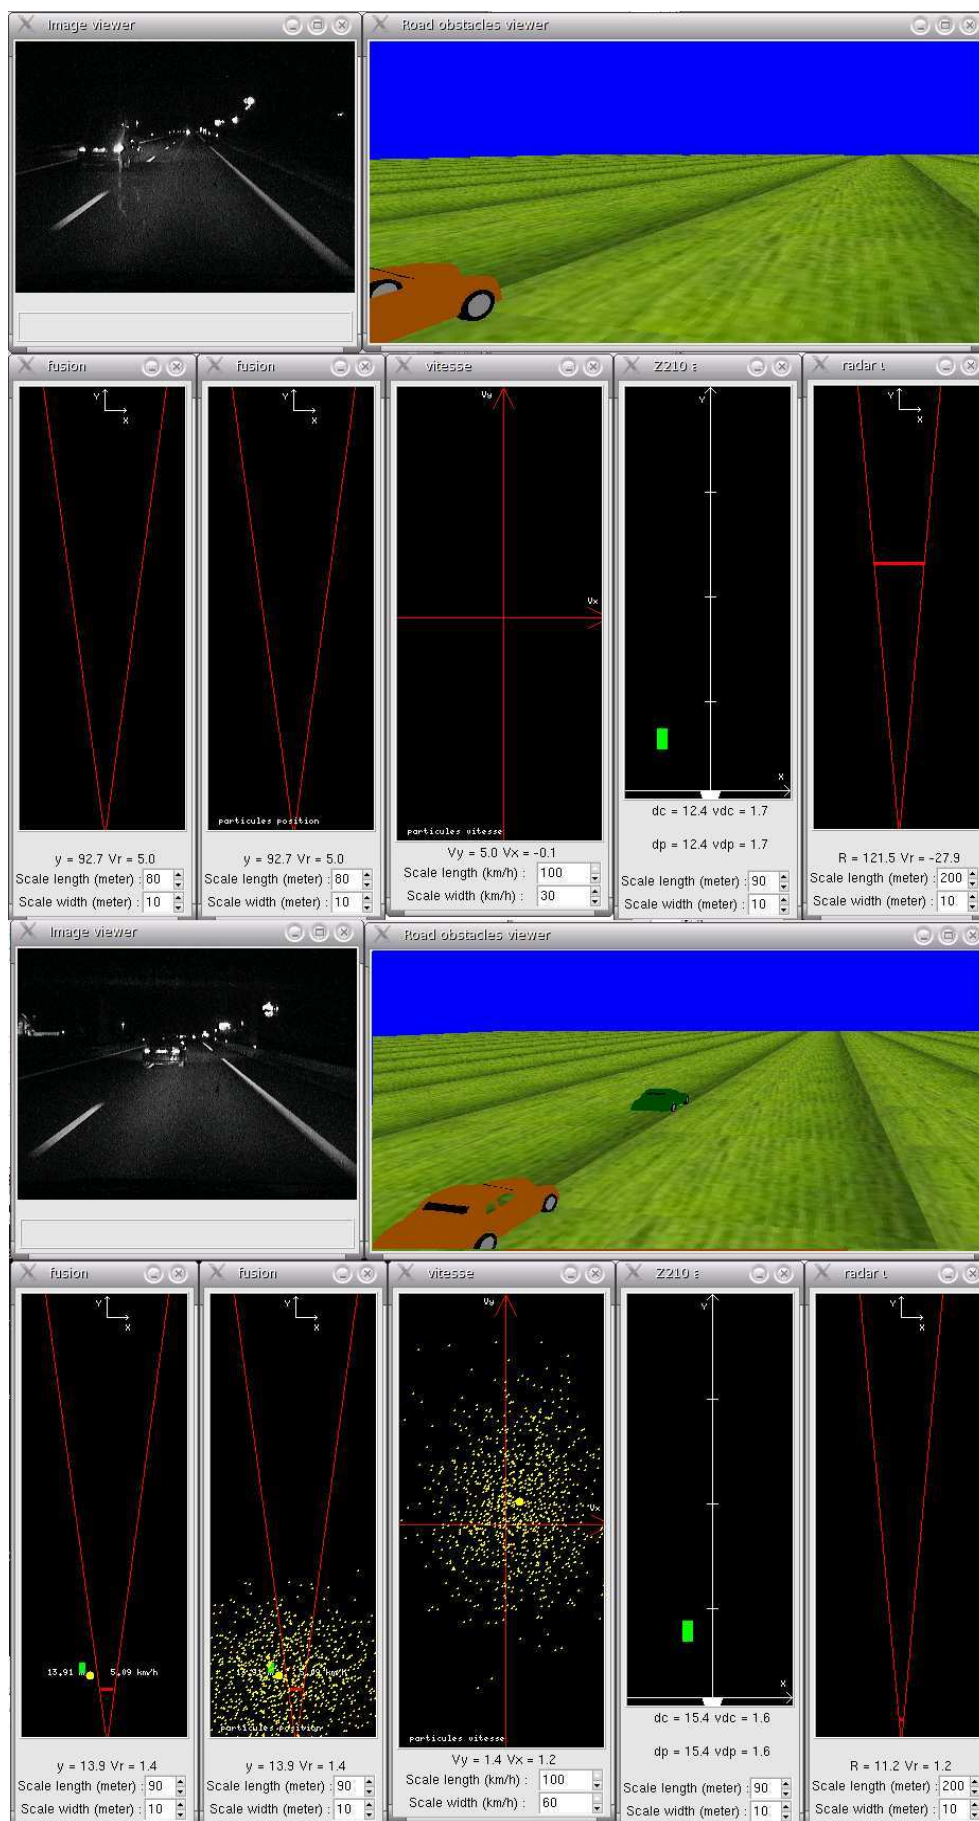


Figure 6.33 — Représentation des résultats (insertion d'un véhicule)

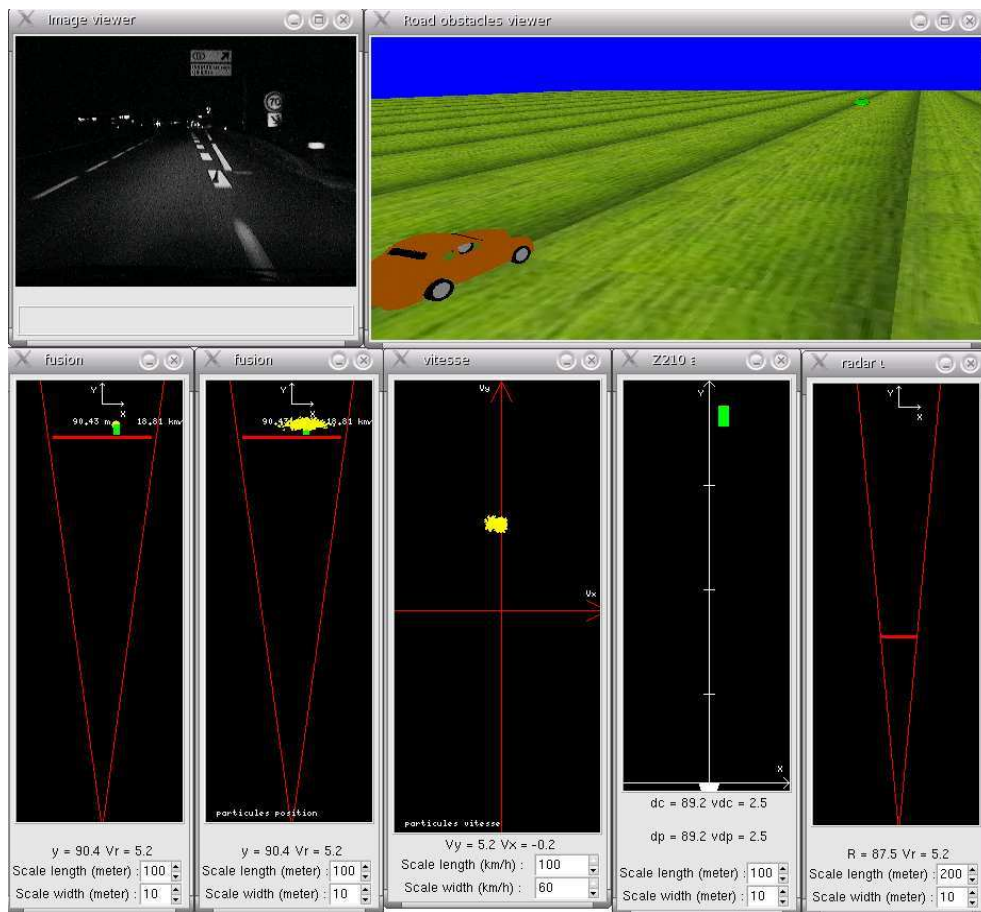


Figure 6.34 — Représentation des résultats (un obstacle à 90m sur autoroute durant la nuit)

### 6.2.3 Conclusion

On a montré ici l'intérêt de la fusion de deux pistages. En effet, l'utilisation d'un seul capteur ne permet pas une caractérisation complète de l'environnement, du point de vue des obstacles, sous toutes les conditions. Par exemple, l'utilisation d'une caméra visible n'est pas adéquate dans des conditions de nuit pour des obstacles lointains (une centaine de mètres). De plus, l'estimation de distance est difficile. Du point de vue de ce radar, il n'est pas possible d'extraire de ses mesures les caractéristiques latérales de l'obstacle détecté. Le lidar ne délivre pas de mesures de vitesses relatives mais seulement une estimation toutes les 500 ms. Un obstacle, ayant comme vitesse relative  $v = 130$  km/h, parcourt 18 m en 500 ms. Il n'est donc pas possible de prendre des décisions robustes quant à l'alerte du conducteur en utilisant le seul capteur télémétrique. Par ailleurs, le système de pistage



propre au capteur peut parfois délivrer des fausses pistes pouvant engendrer des menaces et donc alerter le conducteur sans raison valable.

Toutes ces remarques nous ont poussées à utiliser un système de fusion permettant de qualifier de manière robuste et précise les obstacles de dangereux ou non. Ce système se base sur l'extraction du maximum d'informations possibles sur l'environnement éclairé par les capteurs sous de nombreuses conditions. Effectivement, ce processus de fusion permet dans un premier point d'éliminer les fausses pistes apparaissant dans la zone de recouvrement des deux capteurs. Si une piste radar n'est pas confirmée par une piste lidar (et réciproquement) dans la zone de recouvrement alors c'est une fausse piste. En outre, ce système permet une estimation des caractéristiques essentielles d'un obstacle qui se limitent à la distance, la vitesse et le cap de l'obstacle. Cette estimation, basée sur l'utilisation de filtre de Kalman ou de méthodes particulières, délivre rapidement (cadence du capteur le plus rapide : 8 ms) toutes les caractéristiques essentielles en vue d'une possible alerte. Cette alerte pourra s'appuyer sur l'utilisation des données proprioceptives de la voiture (angle volant, accélérateur, frein, embrayage,...), et donc sur le comportement du conducteur.

### 6.3 Vérité terrain

On décrit ici une manipulation qui nous permet d'avoir une vérité terrain. Pour cela, on équipe l'observateur et la cible de capteurs DGPS. Leurs positions respectives sont données toutes les secondes. La position de la cible est envoyée à l'observateur par modem radio. La cible est pistée par les deux capteurs et les résultats des estimations sont enregistrées. Le processus de fusion est quant à lui testé sur table.

#### 6.3.1 Système de mesures

Le système de mesure comporte deux GPS différentiels omnistar qui délivrent des trames au format TSIP<sup>1</sup>, ces données au format RGF93 en grades sont traduites au format Lambert 2. Ce DGPS donne dans la meilleure configuration une position à  $\pm 40$  cm. Un modem radio de marque Satel reçoit des trames provenant du véhicule cible qui contiennent ses informations de position. Les

---

<sup>1</sup>Trimble Standard Interface Protocol

informations DGPS et modem parviennent à 1 Hz (fréquence maximal que peut fournir le DGPS). La figure 4.11 résume la manipulation effectuée.




Figure 6.35 — Les capteurs mis en jeu

### 6.3.2 Résultats et comparaison des méthodes de fusion

On teste ici les deux types de méthodes de fusion décrites ci-avant. Pour chaque type, on propose d'évaluer les erreurs d'estimation données par la comparaison des deux positions GPS avec la distance radiale disponible à la sortie du module de fusion. De plus, pour la méthode de fusion basée sur l'EKF, on choisit d'intégrer ou pas les prédictions des estimations données par le pistage lidar à chaque instant radar. La figure 6.36 représente l'erreur entre l'estimation de  $r$  à la sortie du module de fusion et la distance donnée par les capteurs GPS.

Au vue des résultats, on peut dire que la performance est correcte pour les deux estimations. Néanmoins, il semble que l'ajout de la prédiction lidar permet un léger gain en précision. La figure 6.37 permet la comparaison des erreurs selon le filtrage utilisé. On ne montre ici que les résultats




Figure 6.36 — Erreur de position sur  $r$

pour les estimations fusionnées sans prédiction des mesures lidar.

On montre l'estimation de  $r$  par la fusion particulière sur la figure 6.38. On caractérise Les erreurs sur la position GPS par des bornes sur cette figure. La performance de l'algorithme utilisant les méthodes particulières est supérieure à celle de l'EKF comme le prouve la figure 6.37. Cependant, son temps de calcul est largement supérieure. Le tableau 4.11 détaille les temps de calcul des deux algorithmes, pou un PC équipé d'un pentium 4 M 1.7 GHz. L'algorithme utilisant les méthodes particulières ne

EKF	0.5 ms
500 particules	12 ms
1000 particules	40 ms
2000 particules	100 ms

Tableau 6.3 — Temps de calcul

pourra donc pas être implémenter pour une utilisation temps réel de la fusion puisque son temps de




Figure 6.37 — Erreur de position sur  $r$

calcul dépasse la période d'acquisition du capteur le plus rapide (8 ms). Les différentes manipulations temps réel utilisent donc l'algorithme basé sur le filtre de Kalman étendu.




Figure 6.38 — Estimation de  $r$  (particules) et position GPS

# Conclusion

Chaque année, un million deux cent mille personnes sont tuées sur les routes mais aussi cinquante millions de personnes sont blessées ou rendues invalides, faisant des accidents de la circulation l'une des premières causes de mort violente dans le monde. C'est pourquoi, ces dernières années, l'effort entrepris par les pouvoirs publics pour faire reculer l'insécurité routière ne cesse d'augmenter. Ces démarches se fondent sur des fonctions telles que la prévention, la responsabilisation, la répression et l'action sur le trio "Infrastructure-Véhicule-Conducteur". La prévention, la répression et la responsabilisation des comportements ont permis de réduire considérablement le nombre de tués ou blessés. Cependant, certaines situations critiques où le conducteur n'est plus en sécurité (visibilité, endormissement,...) sont à la limite des démarches de prévention, de répression et de responsabilisation. Des actions et recherches sur l'approche globale "Infrastructure-Véhicule-Conducteur" sont donc nécessaires. C'est à ce niveau que de nombreux projets existent pour améliorer l'infrastructure, assister le conducteur et sécuriser de manière passive les véhicules. Notre travail se situe au niveau de l'assistance du conducteur et vise à réaliser un système de détection d'obstacles (gestion des inter-distances, prévention des collisions) à l'avant du véhicule capable de fonctionner quelles que soient les circonstances de circulation routières et autoroutières. Ce système se fonde sur l'utilisation d'une information multisensorielle. En effet, la complexité des scènes routières, les circonstances parfois critiques, les limites des capteurs, sont la base du choix multisensoriel effectué.

Après avoir abordé diverses méthodes de détection d'obstacles respectives à des capteurs aux technologies différentes, les caractéristiques des différents capteurs utilisés dans le système ont été présentées. Un capteur télémétrique laser qui permet une représentation de l'environnement en trois dimensions pourra être couplé avec un Radar Pulse Doppler priorité Doppler. De manière analogue le capteur radar pourra être couplé à une caméra infrarouge.

Pour chaque capteur, une extraction des mesures est nécessaire. Les mesures laser sont issues d'une méthode de segmentation des images 3D et de reconnaissance d'obstacles. Le traitement du signal radar permet d'accéder de manière précise à l'information de vitesse relative de l'obstacle couplée à une mesure de porte distance imprécise. Du côté de la caméra infrarouge, la détection d'obstacles utilise une méthode de segmentation basée sur les propriétés des images infrarouge. La position du véhicule est donnée par l'estimation du mouvement propre du véhicule équipé en faisant l'hypothèse d'une route plane.

Chaque capteur est la base d'un système capable de fournir une carte des obstacles présents dans l'environnement éclairé par celui-ci. Cette caractérisation des obstacles s'appuie sur un système complet d'estimation déterministe des paramètres de la trajectoire et de gestion des pistes. L'initialisation, la destruction, la maintenance des pistes sont les briques primordiales du pistage. La maintenance des pistes repose sur les méthodes d'association de données et les méthodes d'estimation. L'utilisation de modèles représentant l'évolution des pistes et des mesures est nécessaire pour l'estimation. Les modèles d'évolution des pistes, à vitesse constante ou à accélération constante semblent convenir à notre application. Le modèle de mesure est quant à lui dépendant du capteur utilisé et des variables d'état considérées. Le caractère linéaire et gaussien des modèles sont la base du choix effectué pour le filtrage. Les filtres de Kalman sont des méthodes optimales dans des cas linéaires et gaussiens. L'utilisation des méthodes particulières permet d'accéder de manière adéquate à l'estimation quand les modèles sont non linéaires et/ou non gaussiens. La sortie d'un tel système propose une description des caractéristiques estimées des obstacles. Cependant, on sait que chaque système connaît des défauts. Le système basé sur le radar délivre parfois des fausses pistes (barrières de sécurité, ponts, terrain, ...). Ces pistes peuvent conduire le système à déclencher une alarme non nécessaire. Il est donc indispensable de combiner ces informations avec d'autres informations qui pourront être redondantes ou complémentaires. La fréquence de mesure du système laser est faible. Couplé avec le système radar, il permet une estimation de la position des obstacles toutes les 8 ms au lieu de toutes les 500 ms. La méthode de combinaison de pistages développée dans ce manuscrit, permet cette estimation. De manière naturelle, le système de fusion observe quelles sont les pistes capteurs pouvant s'associer entre elles. C'est cette étape, association piste à piste, qui permet d'intégrer au filtre les observations respectives à la piste. Après la mise à jour du filtre par les observations, un module de validation confirme que les mesures issues de chaque capteur conviennent à l'entretien de la piste.

## ***Conclusion***

---

La plupart des algorithmes a été validée à partir de l'utilisation de notre véhicule expérimental VE-LAC, dans des conditions réelles de circulation. En particulier, dans le cadre du projet PAROTO une expertise du système a été effectuée. Un des objectifs était de mettre les conducteurs en situations d'alerte : la plupart des conducteurs (90 %) ont affirmé que les signaux visuels les ont aidés à éviter les obstacles et ont pensé que de tels signaux leur ont permis d'avoir des temps de réponses plus rapides.

Cependant, ce système est encore loin d'équiper les véhicules commercialisés étant donné les contraintes diverses en matière d'automobile (coût, esthétique, réglementation,...). Mais il a le mérite de fonctionner de manière robuste dans toutes les circonstances. Une caméra serait le capteur idéal, mais malheureusement cette source d'information ne permet pas une bonne perception dans les cas critiques (brouillard par exemple). L'utilisation d'un capteur radar est donc primordiale pour les systèmes anti-collision du côté des constructeurs automobiles. Il est d'ailleurs communément admis que le radar sera à coup sûr dans le véhicule du futur.

Tout au long de ce manuscrit, on a parlé de la représentation triangulaire de la sécurité routière "Infrastructure-Véhicule-Conducteur". Cependant, nos recherches se sont limitées à la perception de l'environnement à bord des véhicules routiers intelligents, elles sont donc basées sur l'infrastructure et le véhicule. L'information caractérisée par le terme conducteur n'a pas été prise en considération. On pourra donc, peut être, poursuivre nos recherches dans le domaine de la perception en s'appuyant de manière plus importante sur l'information que peut fournir le conducteur humain. L'INRETS a sur ce point amorcé un module de filtrage qui prend en compte toutes les informations proprioceptives du véhicule. De plus, un modèle de simulation cognitive est proposé dans [74], il pourra être la base d'une fusion coopérative d'informations pour la perception de l'environnement dans lequel il évolue. En effet, l'utilisation d'un tel modèle pourrait en outre diriger les actes perceptifs dans les zones critiques autour du véhicule.





# Bibliographie

- [1] V.J. Aidala and S.E. Hammel. Utilization of modified polar coordinates for bearing-only tracking. *IEEE Trans. Automat. Contr.*, vol. AC-28 :p. 283–294, mars 1983.
- [2] A. Antoniadis, J. Berruyer, and R. Carmona. *Régression non linéaire et applications*. Economica ISBN 2-7178-2344-1, 1992.
- [3] M.S. Arulampalam, S. Maksell, N.J. Gordon, and T. Clapp. A tutorial on particle filters for on-line non-linear/non-gaussian bayesian tracking. *Special issue on Monte Carlo Methods for Statistical Signal Processing, IEEE Transactions on signal Processing*, SP-50(2), 2002.
- [4] D. Aubert, D. Gruyer, R. Labayrade, and C. Royere. Détection d’obstacle par fusion de données multi-capteur (stéréovision/laser). Rapport arcsos, Septembre 2004.
- [5] R. Aufrère. *Reconnaissance et suivi de route par vision artificielle, application à la conduite*. PhD thesis, Université BLAISE-PASCAL, Clermont-Ferrand (France), juin 2001.
- [6] R. Aufrère, J. Gowdy, C. Mertz, C. Thorpe, and CC. Wang. Perception for collision avoidance and autonomous driving. In *IMechatronics*, volume 13, pages 1149–1161, december 2003.
- [7] Y. Bar-Shalom and K.C. Chang. Joint probabilistic data association for multiple target tracking with possibly unresolved measurements and manoeuvres. *IEEE Trans. on Automatic Control*, vol. 29 :p. 585–594, july 1994.
- [8] Y. Bar-Shalom and T.E. Fortmann. *Tracking and data association*, volume 179. Mathematics in science and engineering ISBN 0-12-079760-7, 1988.
- [9] Y. Bar-Shalom and X.R. Li. *Estimation and Tracking : Principles, Techniques and Software*. MA : Artech House, 1993.

- 
- [10] Y. Bar-Shalom, X.R. Li, and T. Kirubarajan. Estimation with applications to tracking and navigation. In *New York : John Wiley and Sons*. 2001.
- [11] P. Batavia, D. Pomerleau, and C. Thorpes. Overtaking vehicle detection using implicit optical flow. CMU, Pittsburg (USA), 1997.
- [12] A. Bensrhair, M. Bertozzi, A. Broggi, P. Miché, S. Mousset, and G. Toulminet. A cooperative approach to vision-based vehicle detection. In *4th International IEEE Conference on Intelligent Transportation Systems*, Oakland (USA), august 2001.
- [13] M. Bertossi, A. Broggi, G. Conte, and A. Fascioli. Stereo-vision system performance analysis. In *Enabling Technologies for the PRASSI Autonomous Robot*, pages 68–73, Rome (Italy), january 2002.
- [14] M. Bertossi, A. Broggi, and A. Fascioli. Vision-based intelligent vehicles : State of the art and perspectives. In *Journal of Robotics of Robotics and Autonomous Systems*, volume 32, june 2000.
- [15] S. Blackman and R. Popoli. *Design and Analysis of Modern Tracking Systems*. Boston, MA : Artech House, 1999.
- [16] C. Blanc, R. Aufrère, L. Malaterre, J. Gallice, and J. Alizon. Obstacle detection and tracking by millimeter wave radar. In *IAV 2004*, Lisbonne (Portugal), july 2004.
- [17] C. Blanc, L. Trassoudaine, Y. LeGuilloux, and R. Moreira. Track to track fusion applied to road obstacle detection. In *ISIF 2004(7)*, Stockholm (Suède), June 28–1st july 2004.
- [18] S. Bohrer, T. Zielke, and V. Freiburg. An integrated obstacle detection framework for intelligent cruise control on motorways. In *IEEE Intelligent Vehicles Symposium 1995, IV1995*, 1995.
- [19] K. Bury. Statistical distributions in engineering. In *Cambridge University Press*. 1999.
- [20] P. Chang, T. Camus, and R. Mandelbaum. Stereo-based vision system for automotive imminent collision detection. In *IEEE Intelligent Vehicles Symposium 2004, IV2004*, Parma (Italy), june 2004.
- [21] P. Checchin. *Segmentation d'images de profondeur*. PhD thesis, Université Blaise Pascal, Clermont-Ferrand, France, 1996.

- [22] H. Chen, T. Kirubarajan, and Y. Bar-Shalom. Performance limits of track-to-track fusion vs. centralized estimation : Theory and application. In *IEEE transactions on Aerospace and Electronics Systems*, volume 39 issue 2, pages 386–400, avril 2003.
- [23] Y. Chen and Y. Rui. Real-time speaker tracking using particle filter sensor fusion. In *Proceedings of the IEEE*, volume 92 issue 3, pages 485–494, mars 2004.
- [24] X. Clady. *Contributions à la navigation autonome d'un véhicule automobile par vision*. PhD thesis, Université Blaise Pascal Clermont-Ferrand (France), 2003.
- [25] S. Coraluppi and C. Carthel. Recursive track fusion for multi-sensor surveillance. In *Information Fusion*, volume 5 issue 1, pages 23–33, mars 2004.
- [26] P. Cornic and al. *Method and system for object detection within angular zone, and its applications*. THOMSON CSF Patent US5598163, 1997.
- [27] T. Dang and C. Hoffmann. Stereo calibration in vehicles. In *IEEE Intelligent Vehicles Symposium 2004, IV2004*, Parma (Italy), june 2004.
- [28] E. D. Dickmanns and A. Zapp. A curvature-based scheme for improving road vehicle guidance by computer vision. In *SPIE Conference on mobile robots*, 1986.
- [29] K. Dietmayer, J. Sparbert, and D. Streller. Model based object classification and object tracking in traffic scenes from range images. In *IEEE Intelligent Vehicles Symposium 2001, IV2001*, Tokyo (Japan), juin 2001.
- [30] A. Doucet. *Monte Carlo Methods for Bayesian Estimation of Hidden Markov Models. Application to Radiation Signals*. PhD thesis, Université Paris-Sud, Orsay (France), 1997.
- [31] A. Doucet. On sequential monte carlo methods for bayesian filtering. Rapport technique, université de cambridge, département d'engineering, 1998.
- [32] A. Doucet, N. de Freitas, and N.J. Gordon. *Sequential Monte Carlo Methods in Practice*. Number ISBN 0-387-95146-6. Statistics for Engineering and Information Science, Springer, 2001.
- [33] A. Doucet, B.N. Vo, C. Andrieu, and M. Davy. Particle filtering for multi-target tracking and sensor management. In *ISIF 2002(5)*, Maryland (E-U), 2002.
- [34] A. Eidehall and F. Gustafsson. Combined road prediction and target tracking in collision avoidance. In *IEEE Intelligent Vehicles Symposium*, 2004.

- [35] W. Enkelmann. Obstacle detection by evaluation of optical flow fields from image sequences. In *Image and Vision Computing*, volume 9, juin 1991.
- [36] A. Ewald and V. Willhoeft. Laser scanners for obstacle detection in automotive applications. In *IEEE Intelligent Vehicles Symposium 2000, IV2000*, Dearborn (USA), octobre 2000.
- [37] A. Farina and S. Pardini. Track while scan algorithm in a clutter environment. *IEEE Trans. on AES*, pages p. 769–779, septembre 1978.
- [38] U. Franke. Real-time stereo vision for urban traffic scene understanding. In *IEEE Intelligent Vehicles Symposium 2000, IV2000*, pages 267–272, Detroit (USA), octobre 2000.
- [39] U. Franke, A. Joose, and B. Aguirre. Early detection of potentially harmful traffic situations with children. In *IEEE Intelligent Vehicles Symposium 2001, IV2001*, Tokyo (Japan), juin 2001.
- [40] J. Fritz. *Anticollision method for vehicles*. Patent FR2756932, 1998.
- [41] K. Fürstberg and K. Dietmayer. Object tracking and classification for multiple active safety and confort applications using a multilayer laserscanner. In *IEEE Intelligent Vehicles Symposium 2004, IV2004*, Parme (Italy), juin 2004.
- [42] A. Gad, M. Farooq, J. Serdula, and D. Peters. . multitarget tracking in a multisensor multiplatform environment. In *ISIF 2004*, Stockholm (Suède), June 28–1st July 2004.
- [43] J.B. Gao and C.J. Harris. Some remarks on kalman filters for the multisensor fusion. In *Information Fusion*, volume 3 issue 3, pages 191–201, septembre 2002.
- [44] W.R. Gilks and C. Berzuini. Following a moving target-monte carlo inference for dynamic bayesian models. *Journal of the Royal Statistical Society, B*, 63 :p. 127–146, 2001.
- [45] N.J. Gordon, D.J. Salmond, and A.F.M. Smith. Novel approach to nonlinear-non-gaussian bayesian state estimation. *IEE Proc.-F*, vol. 140, no. 2 :p. 107–113, 1993.
- [46] Y. Le Guilloux, R. Moreira, J. Lonnoy, J. Gallice, L. Trassoudaine, J. Alizon, M.P. Bruyas, H. Tattegrain, A. Chapon, P. Deleurence, and M. Poux. Paroto rapport final. Rapport paroto, février 2004.
- [47] J. Hancock. *Laser intensity-based obstacle detection and tracking*. PhD thesis, The robotics institute, Carnegie Mellon university, Pittsburgh, USA, 1999.
- [48] J. Hancock, M. Hebert, and C. Thorpe. Laser intensity-based obstacle detection. In *IEEE Conference on Intelligent Robots and Systems (IROS)*.

- [49] M. Hariyama, T. Takeuchi, and M. Kameyama. Reliable stereo matching for highly-safe intelligent vehicles and its vlsi implementation. In *IEEE Intelligent Vehicles Symposium 2000, IV2000*, pages 267–272, Detroit (USA), october 2000.
- [50] U. Hofmann, A. Rieder, and E. D. Dickmanns. Radar and vision data fusion for hybrid adaptive cruise control on highways. In *Machine Vision and Applications*, volume 14, pages 42–49, Parma (Italy), 2003.
- [51] J.D. Hol. Resampling in particle filters. Rapport technique, université de linköping, suède, department of electrical engineering, 2004.
- [52] C. Hue, J.P. Le Cadre, and P. Pérez. Sequential monte carlo methods for multiple target tracking and data fusion. In *IEEE Transactions on Signal Processing*, volume 50 issue 2, pages 309–325, février 2002.
- [53] C. Hue, J.P. LeCadre, and P. Pérez. The (mr)mtpf : particle filters to track multiple targets using multiple receivers. In *ISIF 2001*, Montréal (Canada), 2001.
- [54] S. Hun, Z. Jing, and H. Leung. Optimal fusion algorithm baaed on multi-sensor tracking. In *ISIF 2004*, Stockholm (Suède), June 28–1st july 2004.
- [55] D. Hutber. *Suivi multi-capteurs de cibles multiples en vision par ordinateur, appliqué à un véhicule dans un environnement routier*. PhD thesis, Université de Nice, Sophia-Antipolis (France), 1995.
- [56] S. Jouannin. *Association et fusion de données : Application au suivi et à la localisation d’obstacles par radar à bord d’un véhicule routier intelligent*. PhD thesis, Université BLAISE-PASCAL, Clermont-Ferrand (France), janvier 1999.
- [57] S. J. Julier and J. K. Uhlmann. A new extension of the kalman filter to nonlinear systems. *Proc. of AeroSense : The 11th Int. Symp. on Aerospace/Defence Sensing, Simulation and Controls*, 1997.
- [58] R.E. Kalman. A new approcah to linear filtering and prediction problems. *Trans. ASME, Journal of Basic Engineering*, vol. 82 :p. 35–45, mars 1960.
- [59] T. Kato, T. Tanizaki, T. Ishii, H. Tanaka, and Y. Takimoto. 76 ghz high performance radar sensor featuring fine step scanning mechanism utilizing nrd technology. In *IEEE Intelligent Vehicles Symposium 2001, IV2001*, Tokyo (Japan), juin 2001.

- [60] A. Kirchner and C. Ameling. Integrated obstacle and road tracking using a laser scanner. In *IEEE Intelligent Vehicles Symposium 2000, IV2000*, Dearborn (USA), october 2000.
- [61] C. Knoepell, B. Michaelis, and A. Schanz. Robust vehicle detection at large distance using low resolution cameras. In *IEEE Intelligent Vehicles Symposium 2000, IV2000*, pages 267–272, Detroit (USA), october 2000.
- [62] B. Kumar. *Detection system*. MARCONI GEC LTD Patent EP0498524, 1992.
- [63] H. Kuroda, S. Kuragaki, T. Minowa, and K. Nakamura. An adaptive cruise control system using a millimeter wave radar. In *IEEE Intelligent Vehicles Symposium 1998, IV1998*, Stuttgart (Germany), october 1998.
- [64] R. Labayrade, D. Aubert, and J.P. Tarel. Real time obstacle detection in stereovision on non flat road geometry through v-disparity representation. In *IEEE Intelligent Vehicles Symposium 2002, IV2002*, Paris (France), june 2002.
- [65] J. Laneurit. Localisation d'un véhicule dans un environnement cartographié par un filtre à particules. In *à paraître*, 2004.
- [66] J. Laneurit, C. Blanc, R. Chapuis, and L. Trassoudaine. Multisensorial data fusion for global vehicle and obstacles absolute positionning. In *IV2003*, pages 138–143, Columbus (E-U), juin 2003.
- [67] D. Langer. *An Integrated MMW Radar System for Outdoor Navigation*. PhD thesis, Carnegie Mellon University, Pittsburg (USA), 1997.
- [68] F. LeGland. Filtrage particulaire. Mathstic chaînes de markov cachées et filtrage particulaire, méthodes particulières (as 67) du département stic, 2002.
- [69] X.R. Li and V.P. Jilkov. Survey of maneuvering target tracking. part i : Dynamic models. In *IEEE Trans. on Aerospace and Electronic Systems*, volume 39, pages 1333–1363, octobre 2003.
- [70] J.S. Liu and R. Chen. Sequential monte carlo methods for dynamic systems. *Journal of the American Statistical Association*, 93 (443) :p. 1032–1044, 1998.
- [71] H. Maitre. *Traitement des images de RSO*. Hermès Collection IC2, 2001.
- [72] L. Malaterre. Système d'acquisition de données d'un radar automobile 77 ghz. Rapport d'Ingénieur CNAM, Clermont-Ferrand, France, mars 2003.

- [73] P.A. May. *Vehicle duplex doppler near-obstacle detection apparatus*. DELCO ELECTRONICS CORP Patent EP0367404, 1990.
- [74] P. Mayenobe. *Perception de l'environnement pour une gestion contextualisée de la coopération homme-machine*. PhD thesis, Université Blaise Pascal, Clermont-Ferrand, France, 2004.
- [75] R. Möbus and U. Kolbe. Multi-target multi-object tracking, sensor fusion of radar and infrared. In *IEEE Intelligent Vehicles Symposium 2004, IV2004*, Parma (Italy), juin 2004.
- [76] A. Mendes, L. Conde Bento, and U. Nunes. Multi-target detection and tracking with a laser-scanner. In *IEEE Intelligent Vehicles Symposium 2004, IV2004*, Parme (Italy), juin 2004.
- [77] D. Musicki and R.J. Evans. Joint integrated probabilistic data association. In *ISIF 2002*, Annapolis, Maryland (E-U), 2002.
- [78] D. Musicki, R.J. Evans, and S. Stankovic. Integrated probabilistic data association. *IEEE Trans. on Automatic Control*, vol. 39(6) :p. 1237–1241, 1994.
- [79] D. Musicki and M.R. Morelande. Gate volume estimation for target tracking. In *ISIF 2004*, Stockolm (Suède), June 28–1st july 2004.
- [80] D. Musicki, B.F. La Scala, and R.J. Evans. Integrated track splitting filter for manoeuvring targets. In *ISIF 2004*, Stockolm (Suède), June 28–1st july 2004.
- [81] C. Musso, N. Oudjane, and F. LeGland. Improving regularised particle filters. *Sequential Monte Carlo Methods in Practice*, 2001.
- [82] L.Y. Pao and R.M. Powers. A comparison of several different approaches for target tracking with clutter. *American Control Conference*, pages p. 3919–3924, june 2003.
- [83] A. Papoulis. Probability, random variables, and stochastic processes, 2nd ed. In *New York : McGraw-Hill*. 1984.
- [84] J. Rebut, G. Toulminet, and A. Bensrhair. Road obstacles detection usin a self-adaptive stereo vision sensor : a contribution to the arcos project. In *IEEE Intelligent Vehicles Symposium 2004, IV2004*, Parma (Italy), june 2004.
- [85] D.B. Reid. An algorithm for tracking multiple targets. *IEEE Trans. on Automatic Control*, vol. 24 :p. 843–854, décembre 1979.
- [86] G. Rill. Vehicle dynamics. In *Lecture notes*. 2003.



- [87] B. Ristic, M.S. Arulampalam, and N.J. Gordon. *Beyond the Kalman Filter-Particle Filters for Tracking Applications*. Number ISBN 1-58053-631-X. Artech-House, 2004.
- [88] B. Ristic, S. Arulampalam, and J. McCarthy. Target motion analysis using range-only measurements : algorithms, performance and application to isar data. *Signal Processing*, vol. 82 :p. 273–296, 2002.
- [89] A. Rossetini and al. *Radar detector for vehicle suitable in close range applications*. SMA SIGNALAMENTO MARITIMO ED Patent EP0487464, 1992.
- [90] B.F. La Scala and A. Farina. Choosing a track association method. *Information Fusion (3)*, pages p. 119–133, 2002.
- [91] B.F. La Scala and G.W. Pulford. A viterbi algorithm for data association. *35th Conf. on Decision and Control*, décembre 1996.
- [92] M.I. Skolnik. *Introduction to Radar Systems*. Me Graw Hill inc ISBN 0-07-057909-1, 1980.
- [93] A. Sole, O. Mano, G. Stein, H. Kumon, Y. Tamatsu, and A. Shashua. Solid or not solid : Vision for radar target validation. In *IEEE Intelligent Vehicles Symposium 2004, IV2004*, Parma (Italy), juin 2004.
- [94] T.L. Song. Observability of target tracking with range-only measurements. *IEEE Journal of Oceanic Engineering*, vol. 24(NO. 3), july 1999.
- [95] C. Stiller, J. Hipp, C. Rossig, and A. Ewald. Multisensor obstacle detection and tracking. In *Image and Vision Computing*, volume 18, pages 389–396, 2000.
- [96] S. Sun and Z. Deng. Multi-sensor optimal information fusion kalman filter. In *Automatica*, volume 40, pages 1017–1023, juin 2004.
- [97] C. Thorpe, M. Hebert, T. Kanade, and S. Shafer. Vision and navigation for the canergie-melon navlab. In *IEEE Transactions on Pattern Analysis and Machine Intelligence*, volume 10, pages 362–373, 1988.
- [98] P. Tichavsky, C. Muravchik, and A. Nehorai. Posterior cramer-rao bounds for discrete-time nonlinear filtering. *IEEE Trans. Signal Processing*, vol. 46(5) :p. 1386–1396, mai 1998.
- [99] L. Trassoudaine. *Solution multisensorielle temps réel pour la détection d’obstacles sur route*. PhD thesis, Université Blaise Pascal, Clermont-Ferrand, France, 1993.

- [100] H.L. Van Trees. Detection, estimation, and modulation theory (part i). In *John Wiley and Sons*. 1968.
- [101] T. Uebo, T. Kitagawa, and T. Iritani. Short range radar utilizing standing wave of microwave or millimeter wave. In *IEEE Intelligent Vehicles Symposium 2001, IV2001*, Tokyo (Japan), juin 2001.
- [102] E.A. Wan and R. van der Merwe. The unscented kalman filter for nonlinear estimation. In *IEEE Symp. Adaptive Systems for Signal Processing, Comm. and control (AS-SPCC)*, pages p. 153–158, Lake Louise (Canada), 2000.
- [103] X. Wang, S. Challa, and R.J. Evans. Gating techniques for maneuvering target tracking in clutter. *IEEE Transactions on Aerospace and Electronic Systems*, vol. 38 (3) :p. 1087–1097, july 2002.
- [104] E.W. Weisstein. Chapman-kolmogorov equation. In *Mathworld : A Wolfram Web Ressource*. <http://mathworld.wolfram.com/Chapman-KolmogorovEquation.html>.
- [105] Y. Bar-Shalom et T. Kirubarajan X. Lin. Multisensor-multitarget bias estimation for general asynchronous sensors. In *ISIF 2004*, Stockholm (Suède), June 28–1st july 2004.
- [106] M. Xie, L. Trassoudaine, J. Alizon, and J. Gallice. Road obstacle detection and tracking by an active and intelligent strategy. In *Machine Vision and Applications*, volume 7, pages 165–177, 1994.
- [107] Y. Xue and D. Morrell. Target tracking and data fusion using multiple adaptive foveal sensors. In *ISIF 2003(6)*, Cairns (Australie), july 2003.
- [108] Zang and al. *Multimode radar for road vehicle blind-zone target discrimination*. DELCO ELECTRONICS CORP Patent US5325097, 1994.
- [109] Y. Zhu, Z. You, J. Zhao, K. Zhang, and X. Rong Li. The optimality for the distributed kalman filtering fusion with feedback. In *Automatica*, volume 47, pages 1489–1493, mars 2001.