

Université d'Artois
Laboratoire de Génie Informatique et d'Automatique de l'Artois

Détection et suivi d'objets dans le cadre de la théorie de l'évidence pour l'aide à la conduite automobile

Thèse de doctorat
pour l'obtention du grade de Docteur de l'Université d'Artois

Spécialité : Génie Informatique et Automatique

Présentée par

Yann LEMERET

Soutenue le 13 Novembre 2006 devant le jury composé de :

P. Vanheeghe	Professeur à l'Ecole Centrale de Lille	Président de jury
M. Rombaut	Professeur à l'Université Joseph Fourier de Grenoble	Rapporteur
O. Colot	Professeur à l'Université des Sciences et Technologies de Lille	Rapporteur
E. Lefevre	Maître de Conférences à l'Université d'Artois	Co-directeur de recherche
D. Jolly	Professeur à l'Université d'Artois	Directeur de recherche
F. Delmotte	Maître de Conférences à l'Université de Valenciennes et du Hainaut Cambrésis	Examineur
L. Duvieubourg	Maître de Conférences à l'Université du Littoral Côte d'Opale	Examineur

Résumé

Les travaux présentés dans ce mémoire s'inscrivent dans le cadre du projet RaViOLi et traitent du suivi multi-objets pour l'aide à la conduite. Dans ce projet, les capteurs utilisés sont : un radar, un lidar et un système de stéréovision. Chaque capteur fournit une liste d'objets détectés avec leurs coordonnées respectives référencées en distance et en angle par rapport à ce capteur. L'utilisation de ces informations s'effectue grâce à la théorie des fonctions de croyance, qui permet de transformer ces données en masses de croyance et de les fusionner. Ensuite, un algorithme de mise en correspondance, basé lui aussi sur la théorie des fonctions de croyance, permet de retrouver les objets dans la scène à chaque nouvelle mesure des capteurs. Cette mise en correspondance s'effectue en comparant la liste des objets de l'instant précédent avec la nouvelle provenant des capteurs, il faut alors retrouver les objets correspondants dans les deux listes. Pour cette étape d'association, nous avons repris un algorithme existant, qui avait été développé par M. Rombaut, et que nous avons modifié pour qu'il s'adapte aux contraintes du projet RaViOLi. Nous comparons donc les résultats obtenus par les deux méthodes d'association ainsi que leurs limites et les avantages des modifications que nous avons apportées. Enfin, nous terminons par une étape de prédiction. Une première prédiction de l'évolution de la position des objets est effectuée à $t + dt$ seconde, où dt représente la période d'échantillonnage du capteur. Cette prédiction est utilisée comme une information supplémentaire dans l'étape d'association des objets pour améliorer le suivi. Une seconde prédiction est réalisée à plus long terme $t+n$ secondes, où n dépend de la vitesse du véhicule. Cette prédiction permet de détecter les véhicules potentiellement dangereux et de prévenir le conducteur suffisamment à l'avance pour qu'il puisse réagir. Des tests sont effectués, sur des données synthétiques puis réelles, pour vérifier la robustesse de l'algorithme dans différentes situations.

Mots clé : Fusion de données, théorie des fonctions de croyance, association d'objets, filtrage de Kalman.

Abstract

This work is a part of the RaViOLi project and is about multi-objects tracking for driver assistance. In this project, the experimental car is fitted with : a radar, a lidar and a stereovision system. A list of detected objects is provided by each sensor including their coordinates given in distance and angle. This information is treated with the belief functions theory which change data in belief masses. Then, a tracking algorithm, also based on belief functions theory, is used to localize again the detected objects in the new objects list provided by the sensors. This association is made by comparing the old objects list to the new one between each sample time, and when an object match in the two lists, it is considered to be the same. An existing tracking algorithm, developed by M. Rombaut, was used and it was modified to fit the constraints of project RaViOLi. A comparison between these two methods of association is shown, as well as their limits and the advantages of the modifications made. Finally, a prediction step is used to predict objects positions at two different times. First, a $t + dt$ second prediction is computed, where dt corresponds to the sampling time of the sensor. This prediction is used as new data in the association step to improve the tracking. Then, a prediction at $t + n$ seconds is done, where n depends of the car speed. Dangerous cars can thus be extracted and an alert can be sent to the driver if necessary. Synthetics and real data are used to test the robustness of the algorithm in several situations.

Keywords : Data fusion, belief functions, objects association, Kalman filter.

Remerciements

Je tiens à exprimer ma gratitude à Madame Michèle Rombaut, Professeur à l'université Joseph Fourier de Grenoble, d'avoir accepté de rapporter ma thèse. Je la remercie aussi pour ses conseils qui m'ont permis d'améliorer la clarté de ce mémoire.

Merci à Monsieur Olivier Colot, Professeur à l'Université des Sciences et Technologies de Lille, d'avoir également accepté de rapporter ma thèse, ainsi que de l'intérêt qu'il a porté à mes travaux.

Un grand merci à Monsieur Philippe Vanheeghe, Professeur à l'Ecole Centrale de Lille, de m'avoir fait l'honneur de présider le jury.

Je remercie également Monsieur François Delmotte, Maître de Conférences à l'Université de Valenciennes et du Hainaut Cambrésis, d'avoir accepté de faire parti du jury.

Merci à Monsieur Luc Duvieubourg, Maître de Conférences à l'Université du Littoral Côte d'Opale, non seulement pour les renseignements qu'il m'a fourni mais aussi d'avoir accepté de participer au jury.

Je remercie également mon directeur de recherche, Monsieur Daniel Jolly, Professeur à l'Université d'Artois et directeur du laboratoire LGI2A, de m'avoir accueilli au laboratoire au sein de l'équipe Décision et Fusion de l'Information.

J'exprime ma reconnaissance à Monsieur Eric Lefevre, Maître de Conférences à l'Université d'Artois, de m'avoir encadré durant ces trois années de recherche et de la disponibilité dont il a fait preuve.

Un grand merci à tous les membres du laboratoire pour l'aide et les conseils qu'ils m'ont apportés. Ils m'ont également permis de passer ces trois années de thèse dans une ambiance conviviale et chaleureuse.

Enfin, je tiens à remercier ma famille et mes amis pour leur soutien durant ces années.

Table des matières

1	État de l’art	16
1.1	Aide à la conduite	18
1.2	CARSENSE	21
1.3	SAACAM	22
1.4	SAFELANE	23
1.5	INTERSAFE	25
1.6	ARCOS 2003	26
1.7	Argo	27
1.8	Autonomes Fahren	27
1.9	RaViOLi	28
1.10	Méthodes de suivi d’objets	32
1.11	Conclusion	33
2	Présentation des outils utilisés	35
2.1	Théorie des fonctions de croyance	36
2.1.1	Notions de base	36
2.1.2	Fonctions duales	37
2.1.3	Affaiblissement	38
2.1.4	Fusion de fonctions de croyance	38
2.1.5	Conditionnement	41
2.1.6	Choix du cadre de discernement	41
2.1.7	Décision	42
2.1.8	Mesures d’incertitude et de conflit	48
2.2	Filtrage	50
2.2.1	Filtrage optimal	51

2.2.2	Filtre de Kalman Linéaire	52
2.2.3	Filtre de Kalman étendu	53
2.3	Conclusion	54
3	Déroulement de l'algorithme	55
3.1	Création des masses	56
3.2	Association d'objets	58
3.2.1	Formalisme mathématique	58
3.2.2	Nouvelles Formules	60
3.2.3	Comparaison entre les deux algorithmes	64
3.3	Prédiction	72
3.3.1	Kalman linéaire	72
3.3.2	Filtre de Kalman Etendu	74
3.4	Conclusion	75
4	Expérimentations	77
4.1	Données synthétiques : Le simulateur	78
4.1.1	Comparaison entre les deux algorithmes	80
4.1.2	Prédiction des trajectoires	82
4.1.3	Bouclage de la prédiction	85
4.2	Données réelles : camscope numérique	86
4.2.1	Prédiction des trajectoires	97
4.2.2	Influence du bouclage	101
4.3	Conclusion	104

Table des figures

1.1	Comparaison du nombre de morts (compté à 6 jours) entre l'année 2004 et 2005 pour chaque mois de l'année.	17
1.2	Interconnexion du système selon les différentes phases d'action. (Source FEBIAC : FÉdération Belge de l'Industrie de l'Automobile et du Cycle) . .	19
1.3	Le prototype Carsense.	21
1.4	Le véhicule STRADA de l'Université de Technologie de Compiègne.	23
1.5	Types d'informations prises en compte par le système SAFELANE.	24
1.6	Possibilité du système INTERSAFE.	25
1.7	Stéréoscope expérimental fabriqué à partir d'une seule caméra, d'un prisme et de deux miroirs.	30
2.1	Présentation graphique de la fusion entre deux sources d'information m_1 et m_2	39
3.1	Déroulement de l'algorithme complet.	56
3.2	Evolution du coefficient d'affaiblissement α_0 en fonction de la distance de l'objet détecté.	57
3.3	Association entre les objets perçus et connus à partir de l'information de distance.	58
3.4	Evolution de la distance des objets pendant 10s par rapport au capteur. . .	65
3.5	Evolution de la masse de relation entre X_0 et Y_0 , X_0 et Y_1	66
3.6	Association en utilisant les formules de M. Rombaut.	66
3.7	Association en utilisant les formules modifiées.	67
3.8	Evolution de la distance des objets, par rapport au capteur, pendant 10s. .	67
3.9	Evolution de la masse de relation entre X_0 et Y_0 , X_0 et Y_1	68
3.10	Association en utilisant les formules de M. Rombaut.	69

3.11	Association en utilisant les formules modifiées.	69
3.12	Evolution de la fiabilité de la décision en fonction de la fiabilité des mesures.	70
3.13	Evolution de la Non Spécificité en fonction de la fiabilité des mesures.	70
3.14	Variation de la masse pour l'objet 0 en fonction du nombre d'objets présents dans la scène. La masse obtenue avec notre algorithme est tracée en (a) et celle obtenue avec l'algorithme de M. Rombaut est tracée en (b).	71
4.1	Affichage de la simulation.	78
4.2	Evolution de la masse de l'objet 1 ($m_{1,}(X_1RY_1)$) en utilisant les formules de M. Rombaut.	81
4.3	Evolution de la masse de l'objet 1 ($m_{1,}(X_1RY_1)$) en utilisant les nouvelles formules.	81
4.4	Prédiction à $t + 0.05s$ de la trajectoire, en position et en angle, pour l'objet 2 avec un filtre de Kalman linéaire.	82
4.5	Prédiction à $t + 3s$ de la trajectoire, en position et en angle, pour l'objet 2 avec un filtre de Kalman linéaire.	83
4.6	Prédiction à $t + 0.05s$ de la trajectoire, en position et en angle, pour l'objet 2 avec un filtre de Kalman non linéaire.	84
4.7	Prédiction à $t + 3s$ de la trajectoire, en position et en angle, pour l'objet 2 avec un filtre de Kalman non linéaire.	84
4.8	Evolution de la masse de l'objet 2 ($m_{2,}(X_2RY_2)$) avec bouclage de la valeur de prédiction.	85
4.9	Erreur de prédiction sur la distance et sur l'angle avec le filtre Non Linéaire pour une prédiction à $t + dt$ seconde.	86
4.10	Image extraite de la séquence filmée.	87
4.11	Caractérisation des deux caméras virtuelles. La distance en m est calculée à partir de la largeur et de la hauteur, en pixels, du véhicule dans l'image.	88
4.12	Evolution de la distance et de l'angle pour un objet détecté.	89
4.13	Evolution de la masse de croyance pour un objet détecté.	90
4.14	Evolution de la masse sur * sur la totalité de la séquence.	91
4.15	Evolution de la fiabilité des données.	91
4.16	Evolution de la masse de relation, de * et Ω pour la fonction $m_{0,}$ avec un objet perçu.	92

4.17 Evolution de la masse de relation, de $*$ et Ω pour la fonction $m_{.,0}$ avec un objet perçu.	92
4.18 Comparaison de la décision globale (issue des fonctions $m_{0,.}$ et $m_{.,0}$) pour les deux algorithmes. Le tracé du bas correspond à la décision prise avec l'algorithme de M. Rombaut et celui du haut correspond aux formules modifiées.	93
4.19 Evolution de la masse de relation, $*$ et Ω pour $m_{0,.}$ avec un seul objet perçu.	94
4.20 Evolution de la masse de relation, $*$ et Ω pour $m_{.,0}$ avec un seul objet perçu.	94
4.21 Comparaison de la décision globale (issue des fonctions $m_{0,.}$ et $m_{.,0}$) pour les deux algorithmes. Le tracé du bas correspond à la décision prise avec l'algorithme de M. Rombaut et celui du haut correspond aux formules modifiées.	95
4.22 Répartition des probabilités pignistique en utilisant les formules de M. Rombaut	96
4.23 Répartition des probabilités pignistique en utilisant les nouvelles formules .	96
4.24 Taux de rejet en fonction du coût de rejet pour le risque pignistique.	97
4.25 Prédiction à $t + 0.04s$ de la trajectoire pour l'objet 0 en utilisant le filtre de Kalman Linéaire.	98
4.26 Prédiction à $t + 1s$ de la trajectoire pour l'objet 0 en utilisant le filtre de Kalman Linéaire.	98
4.27 Prédiction à $t + 3s$ de la trajectoire pour l'objet 0 en utilisant le filtre de Kalman Linéaire.	99
4.28 Prédiction à $t + 0.04s$ de la trajectoire pour l'objet 0 en utilisant l'EKF. .	100
4.29 Prédiction de la distance et de l'angle pour l'objet 0 à $t + 3s$ en utilisant l'EKF.	101
4.30 Evolution de la masse $m_{0,.}(X_0RY_0)$ en utilisant une seule caméra et la prédiction comme second capteur.	102
4.31 Evolution de la masse $m_{0,.}(X_0RY_0)$ en utilisant les deux sources d'information et la prédiction comme capteur supplémentaire.	103
4.32 Erreur de prédiction sur la distance et sur l'angle avec le filtre Non Linéaire pour une prédiction à $t + dt$ seconde.	103

Notations

Théorie de l'évidence

Ω : cadre de discernement.

N : nombre d'éléments.

A : proposition.

2^Ω : ensemble contenant les 2^N hypothèses A de Ω .

m : fonction de masse.

\emptyset : ensemble vide.

$Pl(B)$: Plausibilité de B .

$Bel(B)$: crédibilité de B .

α : coefficient d'affaiblissement.

m_α : masse affaiblie par le coefficient α .

K : coefficient de conflit.

Q : fonction de communalité.

$|B|$: cardinalité de l'élément B .

\overline{B} : toutes les hypothèses sauf B .

$*$: hypothèse supplémentaire du monde ouvert étendu.

$P(x)$: probabilité de x .

$f(x)$: densité de probabilité.

x : vecteur.

λ : fonction de coût.

a : action.

λ_i : coût associé à l'action i .

R : risque de décision.

D : fonction de décision.

D_B : fonction de décision de Bayes.
 $BetP(H)$: probabilité pignistique de la proposition H .
 E_{Bet} : espérance mathématique pignistique.
 R_* : risque inférieur.
 R^* : risque supérieur.
 R_{Bet} : risque moyen.
 N : fonction de non spécificité.
 D : fonction de discordance.
 S : fonction d'entropie.
 $Confl_m(H_N)$: croyance totale attribuée aux éléments focaux différents de H_N .
 $m_{i.}$, et $m_{.j}$: fonctions de masse.
 (X_iRY_j) : X_i est en relation avec Y_j .
 $(X_i\overline{R}Y_j)$: X_i n'est pas en relation avec Y_j .
 $\overline{(X_iRY_j)}$: X_i est en relation avec un autre objet que Y_j .

Filtrage

$\{X\}_t$: processus Markovien.
 $\{Y\}_t$: observation du processus Markovien.
 F_t : fonction de transition caractérisant la dynamique du système.
 π_t : bruit dynamique de loi connue et de réalisations temporelles indépendantes.
 q_t : noyau de transition du processus Markovien.
 X_t : vecteur contenant les états courants.
 X_{t+1} : vecteur contenant les états de l'instant suivant.
 Y_t : vecteur d'observations.
 H_t : fonction d'observation.
 v_t : bruit de mesure de type blanc Gaussien.
 w_t : bruit de modèle de type blanc Gaussien.
 τ : instant quelconque.
 p : densité de probabilité.
 \hat{X} : estimateur de X .
 dP : probabilité.
 B_t : commande de modèle linéaire.

Q_t : matrice de covariance de w_t .

R_t : matrice de covariance de v_t .

K_t : matrice du gain de Kalman.

P_t : matrice de covariance d'erreur.

C_t : commande du modèle non linéaire

$x(t)$ et $y(t)$: position de l'objet sur l'axe x et y à l'instant t . Coordonnées cartésiennes de l'objet.

v_x et v_y : vitesse de l'objet sur les axes x et y .

γ_x et γ_y : accélération de l'objet sur l'axe x et y .

$(\rho; \Theta)$: distance et angle d'un objet par rapport au capteur. coordonnées polaires de l'objet.

Δt : temps d'échantillonnage variable.

ω : vitesse angulaire maximale.

dt : temps séparant l'instant t de $t + 1$.

$d_{i,j}$: distance séparant l'objet i de l'objet j .

$a_{i,j}$: angle séparant l'objet i de l'objet j .

$e_{i,j}$: écart mesurable entre l'objet i et l'objet j .

λ_d et λ_a : coefficient d'ajustement pour le calcul des masses de relation.

Introduction

Nous avons pu constater ces dernières années une baisse importante de la mortalité routière. Le renforcement des contrôles ainsi que les campagnes publicitaires de la sécurité routière ont fortement contribué à modifier le comportement et à responsabiliser les conducteurs. Cependant, les accidents étant le plus souvent liés à une erreur humaine qu'à une défaillance du véhicule, la baisse de la mortalité doit donc s'effectuer en développant et en généralisant les systèmes d'aide à la conduite. Ces systèmes sont basés sur la perception de l'environnement par l'intermédiaire de capteurs. Les travaux présentés dans ce mémoire montrent le fonctionnement d'un algorithme d'association pour la détection et le suivi d'objets que nous avons développé. Cet algorithme repose sur la fusion de données, fusion qui est réalisée à l'aide de la théorie de l'évidence.

Ce travail de recherche a été réalisé au Laboratoire de Génie Informatique et d'Automatique de l'Artois (LGI2A) dans l'équipe Décision Et Fusion d'Information (DEFI). Notre laboratoire est intégré au projet RaViOLi (Radar Vision Orientable et Lidar). Ce projet consiste à créer un véhicule expérimental capable de détecter des objets à longue distance à l'aide de trois capteurs de nature différente. Notre équipe intervenant dans la phase de fusion haut niveau, l'algorithme présenté est par conséquent utilisable pour RaViOLi.

Ce mémoire se compose de 4 chapitres. Le premier chapitre reprend quelques travaux sur les systèmes d'aide à la conduite. Cet état de l'art décrit les travaux selon les fonctions d'aide apportées au conducteur. La dernière partie du chapitre est consacré à la description du projet RaViOLi ainsi qu'à la description du travail qui est développé dans les chapitres suivants.

La seconde partie du mémoire traite des outils mathématiques utilisés dans l'algorithme de détection et de suivi. Sachant que l'algorithme repose sur la fusion de données,

nous décrivons les principes de la fusion ainsi que les différentes méthodes de décisions dans le cadre de la théorie de l'évidence. Ce chapitre explique aussi les différentes méthodes de prédiction qui seront utilisées pour prévoir l'évolution de la trajectoire des objets.

Le fonctionnement de l'algorithme est décrit dans le troisième chapitre. Nous y montrons les résultats obtenus sur des données artificielles, ainsi qu'une comparaison, uniquement au niveau de l'association, avec le calcul d'association proposé par M. Rombaut. Une seconde partie décrit les modèles utilisés pour la prédiction des trajectoires.

Le dernier chapitre de ce mémoire analyse les performances et la robustesse de l'algorithme sur des données simulées puis réelles. La partie d'association est encore une fois comparée avec celle de M. Rombaut. Nous montrons aussi les résultats de la prédiction ainsi que son utilisation possible pour l'amélioration du suivi des objets.

Enfin, nous concluons et proposons des axes d'évolutions pour l'amélioration de ces travaux.

Chapitre 1

État de l'art

Malgré les efforts du gouvernement pour favoriser l'utilisation des transports en commun, le véhicule personnel reste le moyen de transport préféré des Français. En effet, on constate chaque année, que le trafic est en constante augmentation, ce qui entraîne des répercussions sur l'environnement mais aussi sur la sécurité des usagers. Ces dernières années, afin de limiter les accidents, une attention particulière a été portée sur la sécurité routière. L'insécurité ne provient pas des véhicules en eux même, puisqu'ils sont identiques dans tous les pays, mais bien des êtres humains, qui sont seuls responsables dans 90 à 95% des accidents.

Ainsi, même si l'on constate dans les statistiques une diminution sensible du nombre d'accidents, la France reste loin derrière certain pays comme la Suède ou encore la Grande Bretagne. En 2002, on a enregistré une baisse de la mortalité routière de 6.2%, suivi d'une baisse de 20.9% en 2003 et de 8.7% pour 2004. Pour l'année 2005, l'évolution de la mortalité n'est pas exprimée en pourcentage. En effet, à partir de cette année là, dans un souci d'harmonisation avec les autres pays d'Europe, le nombre de morts n'est plus compté à 6 jours mais à 30 jours après l'accident. Cette modification entraîne des variations importantes sur le décompte des décès. Ainsi pour l'année 2005, il y avait 4990 morts si l'on compte à 6 jours contre 5339 [1] dans les 30 jours.

Par ailleurs, on peut constater sur la figure Fig 1.1 que l'évolution de la mortalité routière n'est pas constante au cours de l'année, même si, globalement, la mortalité est en baisse par rapport à l'année précédente.

En examinant les catégories où l'on trouve le plus grand nombre de tués, on remarque qu'il s'agit des autoroutes dites "de liaison" où l'augmentation atteint 38% pour 2005

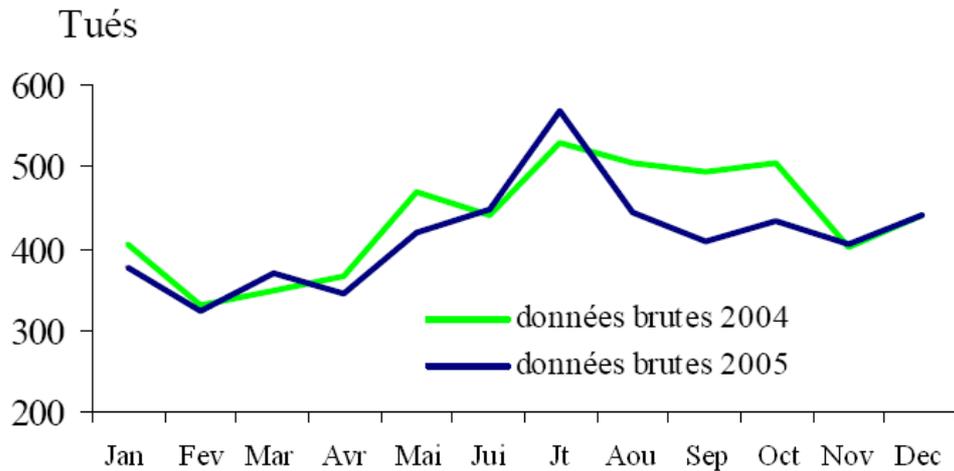


FIG. 1.1 – Comparaison du nombre de morts (compté à 6 jours) entre l'année 2004 et 2005 pour chaque mois de l'année.

par rapport à 2004. Cette catégorie est suivie de près par les piétons et les cyclistes dont l'augmentation de mortalité s'établit respectivement à 15% et 17% entre 2004 et 2005. A l'inverse, on enregistre une baisse de 17.9% sur les autoroutes de dégagements et de 5.7% sur routes nationales ainsi qu'une baisse de 9.6% pour les occupants de véhicules légers.

Parmi les causes d'accidents, on trouve en général :

- les conditions météorologiques : sur l'année 2005, on compte une hausse 7.6% de tués par rapport à la moyenne annuelle pour Janvier contre une baisse de 3.1% en Août.
- l'alcool : en 2004, l'alcool représentait 29.4% du nombre de morts. En 2005, l'alcool représente encore 24.9% des tués.
- la vitesse : le nombre de véhicules dépassant la limitation autorisée (tous réseaux confondus) s'établit en moyenne à 44% pour l'année 2005 contre 49% en 2004.
- l'âge : entre 2004 et 2005 il y a eu une hausse de 13% de tués chez les 15 – 17 ans et de 9.1% pour les 65 ans et plus, contre une baisse de 9.2% chez les 18 – 24 ans.
- la fatigue (l'état de vigilance de façon général), les imprévus, etc.

A noter que certaines personnes auraient pu avoir la vie sauve si elles avaient attaché leur ceinture de sécurité. En effet, en 2004, 8.1% des tués n'avaient pas mis leur ceinture et ce chiffre est passé à 6.7% en 2005.

L'analyse de ces chiffres montre clairement qu'il faut encore améliorer la sécurité routière. Cette amélioration passe en partie par la conception de systèmes d'aide à la conduite.

Ces systèmes font l'objet de la section suivante.

1.1 Aide à la conduite

Les systèmes dit "intelligents", ont pour but d'aider le conducteur à analyser l'environnement dans lequel il évolue. Cette tâche s'effectue en équipant le véhicule de différents capteurs. On peut classer ces capteurs selon leurs modes de fonctionnement :

- Actifs : le capteur émet un signal et il mesure la réflexion de celui-ci pour en déduire des informations (c'est le cas du radar). Il faut néanmoins veiller à ce que le signal émit ne parasite pas des signaux existant et inversement, que les signaux existant ne parasitent pas les capteurs.
- Passifs : cette fois, le capteur se contente d'observer l'environnement sans avoir recours à l'émission d'un signal (par exemple : la caméra).

Les capteurs peuvent aussi être proprioceptifs ou extéroceptifs indépendamment du fait qu'il soit actifs ou passifs. Les capteurs proprioceptifs fournissent des informations propres au véhicule (sa vitesse (tachymètre), l'inclinaison du véhicule (gyroscope), etc), tandis que les capteurs extéroceptifs fournissent des données sur l'environnement dans lequel évolue le véhicule comme les obstacles (radar, lidar, etc) ou encore la détection des lignes blanches (caméra), etc.

Ces capteurs sont ensuite reliés à un système centralisé ou décentralisé qui va traiter les données [2] et interagir avec le conducteur. Selon la situation, le système peut être représenté de différentes façons (Fig. 1.2).

Dans son fonctionnement normal, le but du système est d'assurer la sécurité active. Le système analyse les données capteurs et surveille l'évolution du véhicule, et, en cas de danger, averti le conducteur. A partir de ce moment, soit le conducteur se dégage de cette situation à risque et le système reprend son mode de fonctionnement initial, soit la centrale électronique prend automatiquement le contrôle sur certains organes pour tenter d'éviter ou de limiter les effets de l'accident. Dans le cas où aucune de ces deux manoeuvres ne permettraient de dégager le véhicule de la situation à risque, le système change de mode de fonctionnement et passe dans une phase de sécurité passive. Dès lors, certains éléments de sécurité vont être pré-activés : retendre les pré-tensionneurs de ceinture de sécurité,

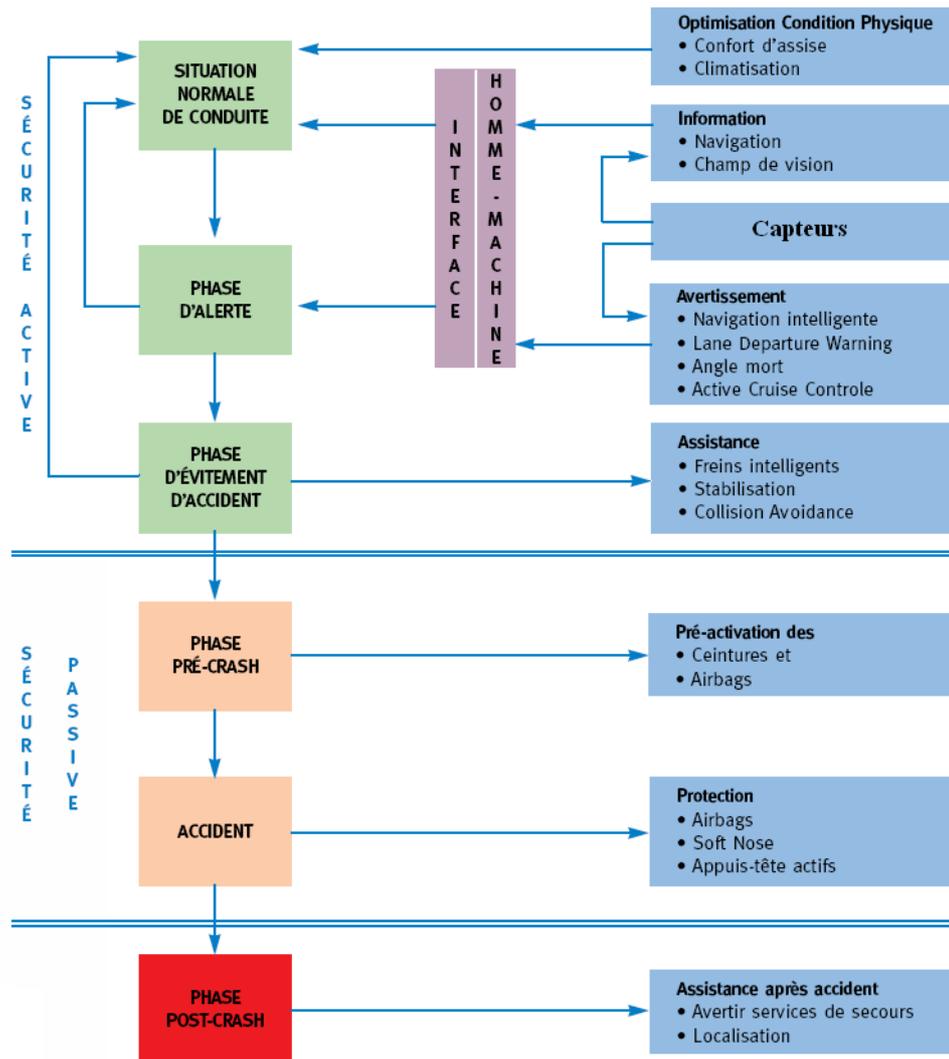


FIG. 1.2 – Interconnexion du système selon les différentes phases d'action. (Source FE-BIAC : Fédération Belge de l'Automobile et du Cycle)

redresser les fauteuils, ajuster les appuis tête, etc. Puis, au moment de l'accident, les derniers systèmes seront employés (les airbags par exemple) afin de protéger au mieux les occupants. Enfin, les secours sont prévenus automatiquement par le véhicule lui même.

Il existe de nombreux travaux dans le cadre des véhicules intelligents. En effet, le terme *véhicule intelligent* ne se limite pas à une seule définition, mais à celle que l'on a assignée au projet. Cette désignation générique fait qu'il n'est pas possible de lister tous les thèmes associés au véhicule intelligent. Ainsi, si on se limite à en définir seulement quelques fonctions, ce véhicule peut être désigné comme étant :

- un véhicule capable de percevoir son environnement, c'est le thème de recherche développé dans le cas du projet Carsense (Sec. 1.2),
- un véhicule équipé d'un système de vision utilisable en environnement urbain, pour la détection d'objets grâce à une caméra omnidirectionnelle (Sec. 1.3), ou encore pour la détection de piétons à partir d'un capteur 3D [3],
- un véhicule capable d'analyser sa propre trajectoire pour prévenir les sorties de route (Sec. 1.4),
- un véhicule assurant une communication avec d'autres véhicules afin d'obtenir des informations à l'approche d'un carrefour (Sec. 1.5),
- un véhicule dont la conduite peut être entièrement automatique (Sec. 1.7 et Sec. 1.8),
- un véhicule avec un système de détection d'obstacles à longue portée pour la prévention des accidents sur autoroute (Sec. 1.9).

Toutefois, on constate que quel que soit l'axe de recherche choisi, la détection d'obstacles ou la perception de l'environnement constituent la base de tous les systèmes d'aide à la conduite.

Par ailleurs, certains projets Européens permettent le développement simultanés de plusieurs des fonctions citées ci-dessus au sein du même projet. Parmi ces projets, on trouve PREDIT avec plus particulièrement ARCOS (Sec. 1.6). Ce projet traite à la fois de la gestion des distances de sécurité, de l'évitement de collision par détection d'obstacles, de la prévention des sorties de route et de la communication avec les autres véhicules sur un accident localisé en aval.

A l'issue du projet, on peut retrouver, en partie ou en totalité, certains systèmes commercialisés sur des véhicules de série. C'est le cas, par exemple, de l'Adaptative Cruise Control (ACC), nommé Stop an Go ACC [4]. Ce système fonctionne, en complément du régulateur de vitesse, grâce à un radar à onde millimétrique. Il permet d'adapter la vitesse du véhicule en fonction de la vitesse des autres véhicules. Lorsque le régulateur est activé, si l'interdistance avec un autre véhicule roulant dans la même file devient inférieure à la distance de sécurité, le véhicule ralentira de lui même pour conserver une distance suffisante. Il accélérera de nouveau pour se remettre à la vitesse mémorisée si la voie est libre.

Les sections suivantes décrivent plus en détails les projets précédemment cités.

1.2 CARSENSE

Le projet CARSENSE [5] fait intervenir le LIVIC (Laboratoire sur les Interactions Véhicules-Infrastructure-Conducteurs), pour la perception, à basse vitesse, de l'environnement d'un véhicule. Le but de ce projet est de restituer le plus fidèlement possible, sous forme de carte, l'environnement dans lequel le véhicule se trouve. Cette carte est au cœur du système d'aide à la conduite. Pour la constituer, il faut récupérer les observations des capteurs sur un ou plusieurs objets et regrouper ces informations de façon à estimer certains de leurs paramètres comme leurs positions, leurs vitesses, . . . L'agrégation des informations issues de tous les capteurs s'effectue grâce à la théorie des fonctions de croyance.

Dans CARSENSE, le véhicule est équipé de 6 capteurs (Fig. 1.3) : 2 caméras en stéréovision, une de plus pour le suivi des lignes blanches, un radar à longue portée, un radar à courte portée et un laser. A l'exception de la caméra dédiée au suivi de ligne, tous les capteurs intégrés analysent l'environnement, uniquement à l'avant du véhicule, à la recherche d'objets.



FIG. 1.3 – Le prototype Carsense.

La fusion est décentralisée, ce qui permet d'appliquer un traitement adapté à chaque capteur et une meilleure résistance en cas de détérioration d'un ou plusieurs capteurs.

Le module de poursuite local fournit un jeu d'objets détectés et suivis, ce qui signifie, que chaque module est asynchrone par rapport aux autres et qu'il faut donc les recalculer temporellement. Ce recalage s'effectue soit par un filtre de Kalman, soit un par modèle flou, en fonction de la modélisation des données.

Une fois le recalage temporel effectué, il faut fusionner les informations pour obtenir une vision synthétique de l'environnement. L'algorithme de fusion repose sur la reconnaissance des objets d'un instant à l'autre ainsi que la gestion des apparitions et des disparitions d'objets. Généralement, dans le cadre de la fusion, on utilise des opérateurs

disjonctifs, conjonctifs et hybrides. Dans CARSENSE, ces opérateurs ne sont pas utilisés immédiatement pour ne pas dégrader les résultats de la fusion.

L'algorithme d'association multi-objet a été étendu au mode multi-capteur [6], ce qui permet alors d'appliquer uniquement l'opérateur conjonctif. L'association partielle fournit un jeu partiel d'obstacles, et la combinaison de toutes ces associations partielles permet d'aboutir à une association globale.

La plateforme temps réelle embarquée a été testée avec le *RT Maps* (Real Time, Multisensor, Advanced Prototyping Software) data logger développée par l'école des Mines de Paris. Ce logiciel permet de connecter facilement tout type de capteurs et actionneurs, d'acquérir, d'enregistrer, de traiter et de transmettre toute donnée, en temps réel. Les calculs ont été effectués sur un pentium III 800MHz. Le temps de calcul pour l'association globale avec 20 objets est de 29ms en utilisant 1 capteur et de 158ms avec 5 capteurs.

On pourra ajouter, pour terminer, que la plateforme *RT Maps* a été jugée performante et a donc été industrialisée et commercialisée.

1.3 SAACAM

Le projet SAACAM (Système Actif d'Aide à la Conduite pour AMéliorer la sécurité automobile) s'inscrit dans le cadre du pôle régional DIVA (DIagnostic et Véhicules Avancés) de la région Picardie. Ce projet est réalisé par le CREA (Centre de Robotique d'Electrotechnique et d'Automatique) en collaboration avec le laboratoire Heudiasyc de l'Université de Technologie de Compiègne (UTC). Le but de ce projet est de développer de nouveaux dispositifs pour la détection de situation à risque. Dans ce projet, deux approches ont été étudiées : tout d'abord la détection des dangers sur l'axe de déplacement du véhicule (longitudinal) et qui a été traité dans [7], ensuite, la détection latérale ainsi que la détermination du positionnement des autres véhicules [8].

Le véhicule instrumenté utilise 2 capteurs extéroceptifs : un laser 2D (SICK LMS 200) et une caméra omnidirectionnelle (fixe mais avec un champ de 360°). Il est aussi équipé de capteurs proprioceptifs (odomètre, ABS) et il intègre en plus un GPS avec récepteur différentiel et Système d'Information Géographique (SIG).

Le projet comporte trois points essentiels : l'acquisition des données capteurs, le développement d'une plateforme de perception et la transmission des informations au conducteur par une Interface Homme-Machine (IHM). Le véhicule ne dispose d'aucun autre ef-

fecteur, le système ne peut donc pas prendre le contrôle du véhicule, il s'agit d'un système d'aide par alertes.



FIG. 1.4 – Le véhicule STRADA de l'Université de Technologie de Compiègne.

Des essais ont été effectués en situation réelle avec le véhicule "STRADA" appartenant à l'UTC (Fig. 1.4). Le conducteur est prévenu par trois voyants de couleurs différentes (vert \rightarrow orange \rightarrow rouge) en fonction de la dangerosité de la situation. Le choix de la couleur s'effectue par un système de décision basé sur la théorie des fonctions de croyance. Les premiers essais ont tout d'abord été réalisés sur une voie à sens unique avec une vitesse maximale de 50Km.h^{-1} , sans et avec véhicules potentiellement dangereux, pour déceler les fausses alarmes et le changement d'état du voyant entre vert et orange. Enfin, le système a été testé sur une voie rapide, à sens unique, avec une vitesse de 80Km.h^{-1} et des véhicules proches pour la détection du danger maximale (voyant rouge). Dans ces conditions, le système fonctionne bien mais n'a semble-t-il jamais été testé lorsque les conditions de perception de l'environnement ne sont pas aussi parfaites.

1.4 SAFELANE

Le projet SAFELANE [9] est intégré dans le projet PReVENT IP dans le domaine "Lateral support and driver monitoring". Safelane a pour but de développer un système anti sortie de route qui fonctionnerait de façon fiable dans divers environnements routiers. Si le système détecte un changement de voie non souhaité, il peut prévenir le conducteur, ou, prendre le contrôle du volant. La nouvelle approche mise en avant dans Safelane sera démontrée au cours de tests, sur différents types de routes. Les capteurs utilisés dans

Safelane sont : une caméra et des cartes digitalisées ainsi qu'un ou plusieurs capteurs actifs (radar, lidar, laser).

Les principaux objectifs de Safelane sont de développer, tester et valider le système. Ce système devra être fiable et utilisable légalement dans les véhicules. Il sera principalement prévu pour fonctionner sur autoroute, nationales et départementales.

Ce système est basé sur la fusion entre les données caméra et des cartes digitales (co-opération avec le projet Maps & Adas aussi intégré à PReVENT) ainsi que des données en provenance des capteurs actifs. La réponse du système sera déterminée en fonction de l'analyse de la situation du véhicule, ce qui inclut le calcul précis de sa trajectoire et la prise de contrôle sur la direction de façon à assister le conducteur si il y a détection d'une possible sortie de route. Le système Safelane est représenté sur la figure Fig. 1.5.

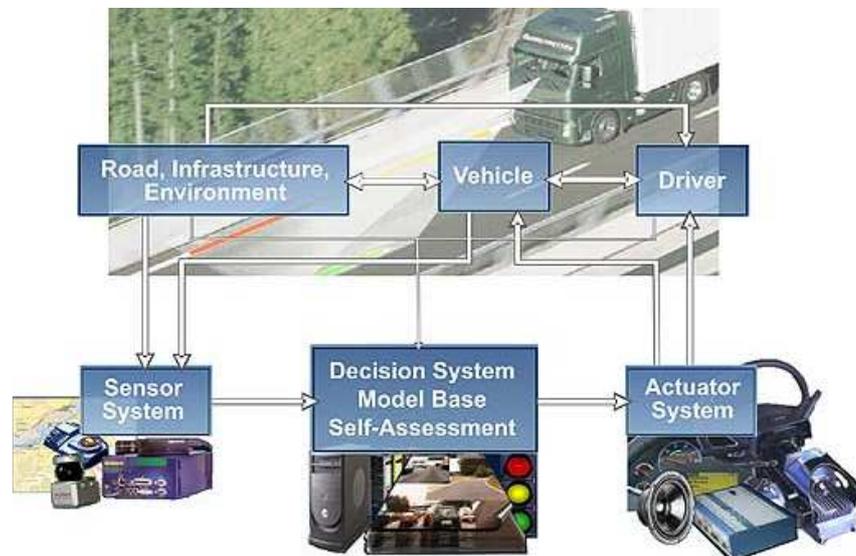


FIG. 1.5 – Types d'informations prises en compte par le système SAFELANE.

Le système réagit donc en fonction du véhicule, de l'infrastructure, du trafic et de l'environnement. La mesure prépondérante est celle de la caméra, qui surveille la route. En cas de début de sortie de route, un signal sonore ou haptique prévient le conducteur et un effecteur agit sur la direction en accord avec une application spécifique gérant l'Interface Homme-Machine.

La contribution essentielle vient de la décision, car elle est prise en ayant analysé les données capteurs, détecté la voie, prédit la trajectoire la plus probable, déterminé la trajectoire à prendre pour remettre le véhicule sur la route et synthétisé le tout pour déclencher les alertes et contrôler le volant. Dans une situation où le système est susceptible d'intervenir, le conducteur en sera informé et un indice de confiance lui sera fourni.

1.5 INTERSAFE

Le projet INTERSAFE [10] est lui aussi intégré dans le projet PReVENT IP mais dans le domaine "Intersection safety". Les accidents au niveau des intersections résultent souvent d'une erreur de la part d'un conducteur comme le manque d'anticipation, ou d'une inattention au passage de la signalisation routière. Le développement des nouveaux systèmes permettent de localiser les véhicules et de prédire leurs trajectoires, combiné à la transmission d'informations, cela devrait permettre de prévenir les conducteurs d'une situation à risque (Fig. 1.6).

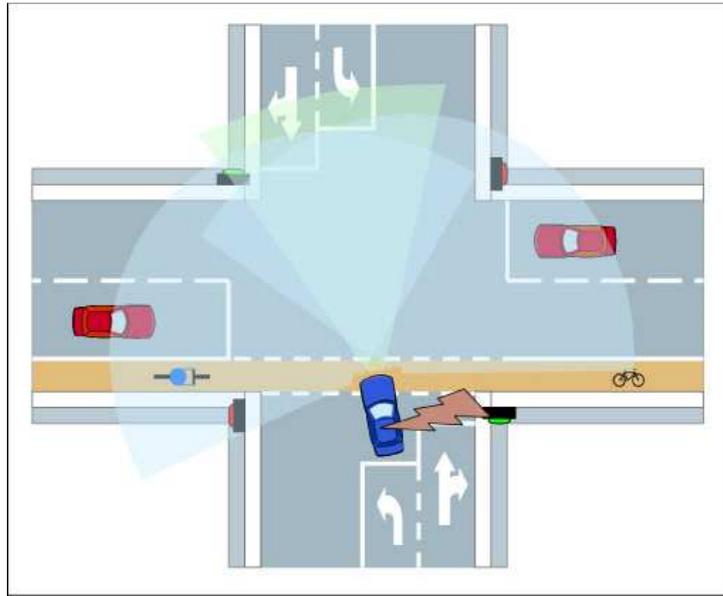


FIG. 1.6 – Possibilité du système INTERSAFE.

INTERSAFE se concentre sur la prévention des accidents aux abords des carrefours et des possibles solutions pour les éviter ou limiter leurs conséquences. Le système sera d'abord évalué sur un simulateur puis sur un démonstrateur.

L'algorithme pour la localisation du véhicule comporte une phase de fusion entre un laser à balayage et une caméra. Le laser a pour but de détecter et classifier les obstacles. La communication est du type véhicule-infrastructure.

Un prototype est en cours de développement pour montrer le fonctionnement de ce système d'alertes conducteur en utilisant des scénarii à haut risques de collision.

1.6 ARCOS 2003

Le PREDIT est un Programme de Recherche, d'Expérimentation et D'Innovation dans les Transports terrestres, initié et conduit par les ministères chargés de la recherche, des transports, de l'environnement et de l'industrie, l'ADEME et l'ANVAR. Stimulant la coopération entre secteurs public et privé, ce programme vise à favoriser l'émergence de systèmes de transport économiquement et socialement plus efficaces, plus sûrs, plus économes en énergie, et finalement mieux respectueux de l'homme et de l'environnement.

ARCOS 2003 (Action de Recherche pour une CONduite Sécurisée) s'inscrit dans le cadre des actions fédératives du PREDIT. Ce projet concerne l'amélioration de la sécurité routière, en se fixant un objectif de réduction des accidents d'environ 30%. En partant d'une approche globale du système "véhicule-infrastructure-conducteur", le projet consiste à sécuriser la conduite automobile sur la base des quatre fonctions techniques suivantes :

- Gérer les interdistances entre véhicules
- Prévenir les collisions sur obstacles fixes, arrêtés ou lents
- Prévenir les sorties de route
- Alerter les véhicules en amont d'accidents / incidents

Le pilotage de ces quatre fonctions en termes de spécifications techniques est au cœur du projet ARCOS, et constitue son originalité.

Géré de façon analogue aux projets industriels, ARCOS est organisé selon dix thèmes, qui permettent d'intégrer les apports des sciences de l'ingénieur, des sciences humaines, et des sciences sociales :

1. Techniques de perception [11, 12, 13, 14].
2. Autres techniques de mesure.
3. Traitement de l'information & élaboration de l'action.
4. Communication.
5. Simulation, évaluation & accidentologie.
6. Système Homme-Machine.
7. Acceptabilité sociale individuelle.
8. Autres aspects socio-techniques collectifs.
9. Moyens expérimentaux.

10. Pilotage fonctions, assistance technique ARCOS.

La problématique d'ARCOS 2003 se résume de la façon suivante : le projet vise à anticiper une "défaillance" grave du système conducteur-véhicule, quelle qu'en soit la cause, puis à agir en assistant le conducteur selon trois modes de gestion des situations limites. Ces modes de gestion de l'urgence permettent d'identifier les objectifs du projet : alerte du conducteur, intervention automatique marginale en mode coopératif homme-machine, intervention automatique d'urgence.

1.7 Argo

Pour le projet Argo [11], développé au Dipartimento di Ingegneria dell Informazione de l'Université de Parme, le but est de créer un système d'aide qui a la capacité de prendre le contrôle total du véhicule si le conducteur ne souhaite plus conduire. Le véhicule n'est équipé qu'avec des capteurs passifs : 2 caméras en stéréovision et d'un capteur de vitesse. Le volant est motorisé pour permettre la conduite automatique. Les images stéréoscopiques sont traitées en temps réel grâce à un ordinateur embarqué et permettent de détecter les obstacles mais aussi de garder le véhicule sur la route et dans sa file. Il est possible de sélectionner le niveau d'intervention du copilote intelligent, depuis la conduite manuelle jusqu'à la conduite automatique en passant par l'aide à la conduite. Les tests ont révélés que la détection d'obstacle est limitée, principalement sur les cotés et à longue distance, or la détection est un élément clé du projet. Pour l'instant la conduite automatique se limite à suivre le véhicule situé devant ainsi que les lignes délimitant la voie, mais sans tenir compte des bretelles de sortie ou d'insertion ni même du changement de voie du véhicule (pour doubler par exemple). Dans le but d'une réduction des coûts et de la simplification des calculs, des tests ont été effectués pour comparer la qualité de la détection entre une seule caméra et la stéréovision [14].

1.8 Autonomes Fahren

Le projet Autonomes Fahren [15, 16], concerne le développement d'un véhicule dont la conduite serait automatique et non supervisée, ne dépendant pas de l'infrastructure routière (peinture magnétique, etc.) avec une fiabilité maximale. Les principaux participants du projet sont : Volkswagen, Bosch, University of Braunschweig, University of Armed For-

ced Hamburg, IBEO/Kasprich, and Witt. Ce véhicule est équipé d'un DGPS, une carte digitalisée, 3 lasers (un à l'arrière et 2 à l'avant), plusieurs radars à courte portée sur les 2 cotés du véhicule, un radar à longue portée et un système de stéréovision.

En partant du principe que le conducteur utilise essentiellement la vue, qui lui amène 90% des informations nécessaires, ce projet met l'accent sur la vision des obstacles. La détection et le suivi des objets est assurée par un filtre de Kalman. Ce filtre utilise toutes les informations de chaque capteur, qu'elle soit spécifique ou redondante.

Le véhicule est équipé d'effecteurs pour rendre la conduite entièrement automatique. Tous les calculs et les actions sont effectuées en temps réel par un simple PC.

Étant donné que le filtre fonctionne à partir de toutes les données capteurs, dans de mauvaises conditions climatiques, le système ne prend plus en compte les données fournies par la caméra pour éviter l'utilisation de fausses informations.

1.9 RaViOLi

Le projet dans lequel nous sommes intégrés se nomme RaViOLi : pour "Radar, Vision Orientable et Lidar". Ce projet est régional et regroupe plusieurs laboratoires du Nord Pas de Calais travaillant dans des domaines différents : le LEOST de l'INRETS⁽¹⁾ (Laboratoire Electronique, Ondes et Signaux pour les Transports), le IEMN-DOAE (Institut d'Electronique, de Micro-électronique et de Nanotechnologie-Département d'Opto-Acousto-Electronique) (UVHC⁽²⁾), le LAGIS (Laboratoire d'Automatique, Génie Informatique et Signal) (USTL⁽³⁾), le LASL (Laboratoire d'Analyse des Systèmes du Littoral) (ULCO⁽⁴⁾) et le LGI2A (Laboratoire de Génie Informatique et d'Automatique de l'Artois) (UA⁽⁵⁾).

Certains laboratoires intervenant dans ce projet sont déjà fortement liés notamment dans le Groupement de Recherche en Automatisation Intégrée et Système Homme-Machine (GRAISyHM), dont l'objectif est de fédérer les recherches au niveau régional dans le domaine de l'Automatique.

Dans le cadre de ce projet, l'accent est mis sur la perception longue distance. Une

¹INRETS : Institut National de Recherche sur les Transports et leur Sécurité

²UVHC : Université de Valenciennes et du hainaut Cambrésis

³USTL : Université des Sciences et Technologies de Lille

⁴ULCO : Université du Littoral Côte d'Opale

⁵UA : Université d'Artois

première partie a permis le développement et la caractérisation d'un ensemble de capteurs capable de fonctionner jusqu'à une centaine de mètres. Une seconde partie porte sur la réalisation d'une centrale d'acquisition et de traitements. Actuellement, seul l'environnement *RT Maps*, développé par l'école des Mines de Paris est disponible comme système d'acquisition pour différents capteurs hétérogènes. Le module d'acquisition et de traitements de données qui sera développé dans RaViOLi constituera une alternative au *RT Maps*.

L'objectif final sera de valider l'ensemble des résultats sur le véhicule instrumenté disponible à l'INRETS-LEOST. Ce démonstrateur aura pour but de visualiser sur un écran toutes les données pertinentes issues des capteurs provenant de la zone potentiellement dangereuse, c'est à dire pouvant comporter des obstacles.

Dans ce projet, 3 capteurs sont utilisés : un radar à longue portée, un système de stéréovision et un lidar. Le projet RaViOLi comporte 3 volets :

- un volet vision : mise au point du stéréoscope, caractérisation, traitement d'images (LEOST et LAGIS).
- un volet radar : caractérisation, traitement de signal (LESOT et IEMN)
- un volet centrale d'acquisition : développement du système d'acquisition et de traitement des données des différents capteurs pour permettre la fusion de données haut niveau (LEOST, LAGIS, LASL et LGI2A).

Étant donné que l'intérêt de ce projet par rapport aux autres est de faire de la détection longue distance (environ $100m$), il a été nécessaire de fabriquer des capteurs performants pour une plage de distance élevée.

Le système de stéréovision est composé d'une seule caméra, qui, à l'aide de miroirs latéraux et d'un prisme central, permet de former deux demi images (Fig. 1.7). L'avantage de ce système est que l'on peut orienter les miroirs pour changer la zone de vision sans avoir à recalibrer le système comme c'est le cas avec deux caméras [17]. De plus, ce système produit une vision fovéale (résolution meilleure au centre de l'image que sur les côtés) ce qui correspond à la vision humaine. On peut ainsi avoir une scène de $85 \times 107cm$ à $4.30m$, pour atteindre une zone de $12m$ de large à $100m$. Comme toute caméra, ce système est affecté par les conditions météorologiques.

Les radars utilisés généralement pour les systèmes anti-collisions sont de type Doppler. Ils émettent un faisceau étroit dans la bande $76 - 77GHz$ et peuvent détecter des objets

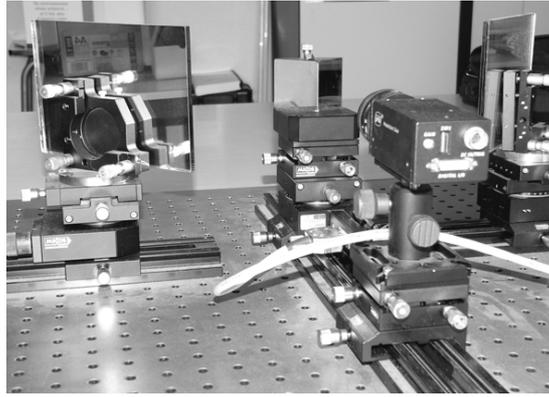


FIG. 1.7 – Stéréoscope expérimental fabriqué à partir d’une seule caméra, d’un prisme et de deux miroirs.

jusque $200m$. Dans le projet RaViOLi le choix du radar s’est porté sur un radar à corrélation. Dans ce cas, le faisceau est plus large, donc la détection s’effectue dans un champ plus important (environ 12°), en revanche, cela entraîne une chute de la portée ($150m$). Il permet de mesurer la vitesse des véhicules dès $1km.h^{-1}$ et jusque $180km.h^{-1}$. Enfin, ce type de radar utilise des puissances d’émission moindre et des codages variés ce qui limite le risque d’interférences avec d’autres radars. Le radar à corrélation se rapproche du radar idéal [18, 19] et permet l’amélioration de la détection des obstacles tout en diminuant le taux de fausses alarmes. Ce radar à l’avantage et l’inconvénient de supprimer les objets fixes. C’est un avantage lorsqu’il s’agit des arbres, des glissières de sécurité, cependant cela devient un inconvénient dans certaines situations car il n’est alors pas capable de détecter une file de véhicule à l’arrêt (bouchon, péages, etc).

Le Lidar, quant à lui, permet de fournir des données précises en terme de distance et d’angle. Il a cependant une portée limitée et tout comme la caméra, il est affecté par les conditions extérieures.

Le traitement est centralisé, il n’y a donc aucun traitement local pour mettre en forme les données capteurs. La carte de traitement est une carte STREAM. Elle a déjà été développée dans le cadre du projet "Carte d’acquisition et de traitement vidéo multi-fonctions pour les applications de surveillance et de détection d’obstacles" mené dans le cadre du programme d’étude à caractère technologique du GRRT (Groupement Régional pour la Recherche dans les Transports). La carte électronique dispose d’un FPGA (Field Programmable Gate Array) programmé pour réaliser le traitement bas niveau de séquences d’images numériques. Cette méthode permet d’avoir un temps de traitement constant,

connu et suffisamment court pour assurer une utilisation en temps réel. Un module externe interfacé à la carte STREAM permet de connecter les différents capteurs et de numériser et de dater les données issues des capteurs de façon à mettre en correspondance uniquement des données décrivant l'environnement au même instant. Ce module renvoie aussi la commande de pilotage pour l'orientation du radar et de la caméra.

La dernière étape du projet est la fusion de données. Grâce à elle, on peut combiner les avantages de chacun des capteurs et réduire leurs défauts. Notre laboratoire ayant un axe de recherche dans la fusion de données haut niveau (données qui ont déjà été traitées pour n'en conserver que les informations essentielles), c'est donc dans cette étape que nous intervenons.

On peut remarquer que le projet RaViOLi ressemble au prototype mis au point au cours de la thèse de Jérôme Pontois [20], qui, fait lui même suite aux démonstrateurs PROCHIP et PROLAB [21]. En effet, le travail de recherche consistait à développer un système d'anti-collision en équipant un véhicule avec 3 capteurs : un radar, un stéréoscope et un laser. Les capteurs étaient ajustés de façon à pouvoir détecter des objets sur 3 voies à 150m à l'avant du véhicule. Les données issues de ces capteurs étaient fusionnées en utilisant la théorie des possibilités avec un opérateur de fusion adaptatif. Enfin, le système fonctionnait en temps réel avec un PC embarqué. Cependant, les capteurs étaient moins performants que maintenant : le radar étant réglé pour mesurer à 150m, il n'était pas capable de détecter en dessous de 50m. Actuellement, il est possible de mesurer entre 0 et 150m avec le même radar. Le stéréoscope était constitué de 2 caméras linéaires fixes alors que dans le cas du projet RaViOLi, il s'agit d'une caméra matricielle dont l'image stéréoscopique est formée par 2 miroirs et un prisme orientable pour diriger la vision. Enfin, les données issues des capteurs dans le cas du projet RaViOLi seront traitées en temps réel par une carte autonome et non pas par un PC.

Le travail de recherche présenté dans ce mémoire s'inscrit dans le cadre du projet RaViOLi dans le volet "centrale d'acquisition". Notre travail consiste à mettre au point un algorithme permettant la détection et le suivi multi-objet en utilisant l'information issue de tous les capteurs.

1.10 Méthodes de suivi d'objets

Un certain nombre de travaux ont déjà été réalisés sur le suivi de cibles [22, 23, 24], y compris dans d'autres domaines que le véhicule intelligent [25, 26, 27]. Les méthodes de suivi d'objets sont pour la plupart probabilistes, et deux d'entre elles sont fréquemment utilisées :

- Le JPDAF (Joint Probabilistic Data Association Filter) [28].
- Le MHT (Multiple Hypothesis Tracker) [29]

Le JPDAF est une évolution du PDAF, proposé lui aussi par Bar-Shalom. Cette méthode repose sur le calcul d'un estimateur à partir des mesures contenues dans une fenêtre temporelle. Contrairement au PDAF, le JPDAF permet d'assurer le suivi multi-cibles. L'inconvénient de cette méthode réside dans le fait qu'il n'est pas possible d'initialiser de nouvelles pistes.

Le MHT est basé sur une méthode orientée mesure. Plutôt que d'associer les mesures aux pistes, on formule trois hypothèses pour les caractériser :

1. La mesure provient d'un objet existant
2. La mesure provient d'un nouvel objet
3. La mesure est une fausse détection

Le choix s'effectue en calculant la probabilité a posteriori de chacune de ces hypothèses en prenant en compte les détections manquantes, les fausses alarmes et la possibilité de l'apparition d'un nouvel objet. Cette méthode permet donc de gérer les apparitions d'objets, cependant, à chaque pas de temps, chaque hypothèse en génère de nouveau trois, ce qui fini par provoquer une explosion combinatoire.

Afin de tirer parti des avantages de ces méthodes, on pourra parfois trouver des méthodes hybrides combinant le MHT pour assurer l'initialisation des pistes et le JPDAF pour assurer leur suivi. Cependant, ces deux méthodes ont un inconvénient commun : il est nécessaire de connaître le taux de fausses alarmes. De plus, ces méthodes étant probabilistes, elles ne permettent pas de gérer l'incomplétude, ni l'incertitude. Afin de résoudre les problèmes engendrés par les méthodes probabilistes et de mieux répondre aux contraintes imposées par le projet RaViOLi, dans l'algorithme de fusion que nous

présentons par la suite, nous avons choisi de développer la partie de suivi d'objets en utilisant la théorie des fonctions de croyance. En effet, le but est de proposer une détection à longue portée, ce qui revient à traiter des informations incertaines car provenant de mesures sur des objets lointains. Par ailleurs, la théorie des fonctions de croyance permet de gérer l'incomplétude des capteurs. Cette absence de données est due au fait que les trois capteurs utilisés dans le projet RaViOLi n'ont pas la même fréquence de fonctionnement, néanmoins chaque capteur date ses données lorsqu'elles sont disponibles. Le système fonctionnera donc en continu avec seulement les mesures provenant du capteur le plus rapide. La fusion ne pourra uniquement être effectuée que lorsque l'un ou l'autre des deux capteurs restant aura des données disponibles. Cet algorithme gère, en plus du suivi, l'apparition et la disparition des objets dans l'environnement routier. Enfin, nous proposons aussi une approche utilisant un filtre prédictif de façon à améliorer le suivi multi-objets en calculant à l'avance la position des objets sur la route.

1.11 Conclusion

Dans ce chapitre, nous avons présenté quelques projets axés sur le véhicule intelligent. Actuellement, dans le domaine des systèmes d'aide à la conduite, il existe un grand nombre de projets de recherche. Néanmoins, tous ces projets ont un point commun : améliorer la sécurité des passagers du véhicule de façon à faire chuter la mortalité routière.

Notre laboratoire est intégré au projet RaViOLi et intervient dans la fusion d'information haut niveau pour la détection d'obstacle. C'est dans ce contexte que l'algorithme de fusion, qui est décrit et testé dans ce mémoire, a été développé. Il s'agit plus précisément d'un algorithme de fusion pour la détection et le suivi d'objets prenant en compte une contrainte de distance : le suivi doit être capable de fonctionner de façon fiable pour des objets lointains.

Les méthodes de suivi existantes permettent déjà d'assurer du suivi multi-objets. Cependant, ces méthodes, pour la plupart probabilistes, ne permettent pas de gérer l'incomplétude et l'incertitude liée aux mesures. Enfin, les méthodes couramment utilisées, telles que le JPDAF ou le MHT, posent des problèmes comme l'initialisation des pistes ou l'explosion combinatoire et nécessite la connaissance du taux de fausses alarmes. C'est pourquoi, pour le développement de l'algorithme que nous proposons, nous avons choisi d'utiliser la théorie des fonctions de croyance [30, 31] pour assurer le suivi des objets.

Cette théorie offre l'avantage de prendre directement en compte les imperfections présentes dans les données de chaque capteur et permet la fusion des différentes sources d'information quelle que soit la nature de cette information. Le chapitre suivant présente les outils théoriques qui seront utilisés par la suite dans ce mémoire.

Chapitre 2

Présentation des outils utilisés

Le but de notre travail de recherche est de détecter et de suivre des objets dans un environnement routier. Nous avons découpé ce travail en deux phases : une association et un suivi.

L'association consiste à déterminer ce que sont devenus à l'instant t les objets vus par les capteurs à l'instant $t - 1$. A chaque pas de temps, les capteurs fournissent une liste d'objets avec leurs coordonnées polaires $(\rho; \Theta)$. La distance et l'angle de chaque objet sont référencés par rapport aux capteurs. A partir de cette liste d'objets parvenue à l'instant t , nous devons déterminer par rapport à la liste d'objets de l'instant $t - 1$ si de nouveaux objets sont apparus, si certains ont disparu et retrouver les autres dans l'environnement. Cette mise en correspondance est possible car l'écart de temps entre deux mesures provenant des capteurs utilisés dans le projet RaViOLi est très faible (environ $1ms$). On peut donc formuler l'hypothèse qu'entre deux mesures la position des objets ne varie pas de beaucoup, même à grande vitesse, et ce n'est qu'à cette condition que l'association peut s'effectuer. Cette association étant réalisée grâce à la théorie des fonctions de croyance, nous commençons tout d'abord par présenter cette théorie. Nous rappelons les notions concernant la définition d'une masse de croyance, son affaiblissement ainsi que la fusion de fonctions issues de plusieurs sources. Nous revenons aussi sur l'importance du choix du cadre de discernement et donnons la définition de quelques mesures d'incertitudes et de conflits qui serviront par la suite à caractériser les fonctions utilisées dans l'algorithme d'association.

La seconde phase est le suivi des objets qui se caractérise par la prédiction des trajectoires des objets perçus. A l'instant t , nous effectuons une prédiction de la position des

objets à $t + 1$. Cette information est ensuite utilisée en correspondance avec la mesure à $t + 1$ pour améliorer l'étape d'association des objets. Nous présentons donc plusieurs méthodes de filtrages permettant de prédire l'évolution de la trajectoire des objets. Nous introduisons de façon générale le filtrage, puis, nous abordons le filtrage optimal avec, pour commencer, le plus facile des filtres à mettre en œuvre : le filtre de Kalman linéaire.

Étant donné le caractère fortement non linéaire du déplacement des véhicules sur une route, nous présentons aussi le filtre de Kalman étendu.

2.1 Théorie des fonctions de croyance

La théorie des fonctions de croyance a été présentée pour la première fois par Dempster [30] dans le cadre de ses travaux sur les probabilités inférieures et supérieures. En utilisant ce formalisme mathématique, Shafer [31] a démontré l'intérêt des fonctions de croyance pour modéliser l'incertitude. L'utilité des fonctions de croyance, comme alternative aux probabilités, a été prouvée de manière axiomatique par Smets [32, 33] au travers du *Modèle des Croyances Transférable* donnant ainsi une interprétation claire et cohérente du concept sous-jacent de cette théorie. Dans ce chapitre, nous allons présenter les concepts mathématiques qui définissent la théorie des fonctions de croyance.

2.1.1 Notions de base

Supposons connu un ensemble Ω que l'on appelle le cadre de discernement, défini de la façon suivante :

$$\Omega = \{H_1, H_2, \dots, H_N\} \quad (2.1)$$

Cet ensemble est constitué de N hypothèses exhaustives et exclusives qui sont autant de solutions possibles au problème posé. A partir de ce cadre de discernement, on peut construire un ensemble noté 2^Ω , qui inclut les 2^N propositions A de Ω tel que :

$$2^\Omega = \{A/A \subseteq \Omega\} \quad (2.2)$$

Une fonction de croyance peut être définie mathématiquement par une fonction de masse (ou allocation ⁽¹⁾), notée $m : 2^\Omega$ dans $[0, 1]$ et qui vérifie :

$$\sum_{A \subseteq \Omega} m(A) = 1 \quad (2.3)$$

¹On trouve souvent dans la littérature le terme *bba* pour *basic belief assignment*

Chaque sous ensemble $A \subseteq \Omega$ tel que $m(A) \neq 0$ est appelé élément focal de Ω . De cette façon, la masse $m(A)$ représente le degré de croyance alloué à la proposition A , et qui, avec la connaissance actuelle, ne peut pas être attribuée à un sous ensemble plus spécifique que A . La fonction de croyance pour laquelle $m(\emptyset) = 0$ est appelée normale. Dans le cas du *Modèle des Croyances Transférables*, la condition $\sum_{\emptyset \neq A \subseteq \Omega} m(A) = 1$ n'est pas imposée et on peut donc obtenir $m(\emptyset) \neq 0$. De cette manière, on peut définir la notion de *monde ouvert* en supposant que la croyance ne peut pas être attribuée à un sous ensemble de Ω . Dans ce cas, l'ensemble vide (\emptyset) peut être vu comme une hypothèse non incluse dans le cadre de discernement Ω et qui vraisemblablement est la solution du problème. Cette notion de *monde ouvert* est en opposition avec la notion de *monde fermé* dans laquelle on suppose le cadre Ω exhaustif. De part la définition d'une fonction de croyance, on peut déduire deux fonctions particulières :

- la fonction d'ignorance totale :

$$m(\Omega) = 1 \tag{2.4}$$

dans ce cas, il a été impossible de répartir la connaissance à un ensemble plus petit que Ω , on a donc aucune connaissance quant à la possible hypothèse solution. Cette fonction de croyance est aussi un élément neutre de la combinaison de Dempster.

- la fonction de certitude totale :

$$m(\{H_n\}) = 1 \tag{2.5}$$

où la masse se concentre sur l'hypothèse singleton H_n . On est alors certain que cette hypothèse est la solution.

2.1.2 Fonctions duales

A partir des masses de croyance, on peut définir d'autres fonctions de croyance comme la plausibilité :

$$Pl(B) = \sum_{A \cap B \neq \emptyset} m(A) \quad \forall B \subseteq \Omega \tag{2.6}$$

Cette fonction peut être interprétée comme la part de croyance qui pourrait être allouée à B tout en prenant en compte les éléments qui ne discréditent pas cette hypothèse. Une autre fonction de croyance que l'on retrouve souvent dans la littérature est la crédibilité :

$$Bel(B) = \sum_{A \subseteq B} m(A) \quad \forall B \subseteq \Omega \tag{2.7}$$

Cette fonction représente la croyance apportée à tous les éléments composant une hypothèse. La plausibilité et la crédibilité sont des fonctions duales. Ces mesures peuvent être vues comme les bornes inférieure et supérieure de la fonction de masse m . De plus, ces différentes fonctions (pl , bel et m) ne font que représenter la même information mais de façon différente et, de ce fait, on peut passer de l'une à l'autre en utilisant la transformée de Möbius [34, 35].

Si Bel et Pl sont respectivement la crédibilité et la plausibilité d'une même fonction de croyance, alors, elles vérifient les relations suivantes :

$$Bel(A \cup B) \geq Bel(A) + Bel(B) - Bel(A \cap B) \quad (2.8)$$

$$Pl(A \cap B) \leq Pl(A) + Pl(B) - Pl(A \cup B) \quad (2.9)$$

$$0 \leq Bel(A) \leq Pl(A) \leq 1 \quad (2.10)$$

$$Bel(A) + Pl(\bar{A}) = Bel(\Omega) = Pl(\Omega) = 1 \quad (2.11)$$

Les équations (2.8) et (2.9) correspondent respectivement aux propriétés de sur-additivité de la crédibilité et de sous-additivité de la plausibilité. De plus, $Bel(A) - Pl(A)$ est une mesure de l'ignorance relativement à A .

2.1.3 Affaiblissement

Lorsque l'information qui génère la fonction de croyance n'est pas totalement fiable, il est possible de l'affaiblir. Cet affaiblissement s'effectue en utilisant un coefficient α qui représente une connaissance de la fiabilité de l'information. Ce coefficient va permettre le transfert d'une partie de la masse de croyance vers Ω . La fonction d'affaiblissement m_α définie par le coefficient de fiabilité α se déduit de m de la façon suivante :

$$\begin{cases} m_\alpha(A) = \alpha m(A) \quad \forall A \subset \Omega \\ m_\alpha(\Omega) = 1 - \alpha + \alpha m(\Omega). \end{cases} \quad (2.12)$$

2.1.4 Fusion de fonctions de croyance

Dans la théorie des fonctions de croyance, la fusion de données provenant de sources distinctes se fait en utilisant la *règle de combinaison de Dempster*, que l'on nomme aussi somme orthogonale. Cette règle est commutative et associative et se définit comme suit :

$$\forall A \in 2^\Omega \quad m(A) = m_1(A) \oplus \dots \oplus m_Q(A) \quad (2.13)$$

où \oplus est l'opérateur de combinaison. En utilisant la propriété d'associativité, il est possible d'effectuer la fusion entre les sources deux à deux :

$$\begin{aligned} \forall A \in 2^\Omega \quad m_{12}(A) &= m_1(A) \oplus m_2(A) \\ m_{123}(A) &= m_{12}(A) \oplus m_3(A) \\ &\vdots \end{aligned} \quad (2.14)$$

Si on considère deux sources notées S_i et S_j , donnant respectivement les fonctions m_i et m_j , alors la combinaison s'écrit :

$$m(C) = \frac{1}{1-K} \sum_{A \cap B = C} m_i(A) \cdot m_j(B) \quad (2.15)$$

et K est défini par :

$$K = \sum_{A \cap B = \emptyset} m_i(A) \cdot m_j(B) \quad (2.16)$$

Dans l'équation (2.15), le coefficient K reflète le conflit existant entre les deux sources S_i et S_j . Ce coefficient varie entre 0 et 1. Lorsqu'il vaut 1, les sources sont en conflit total et les informations ne peuvent être fusionnées. Si K est nul, alors les sources sont en accord. La fusion entre deux sources peut être représentée graphiquement (Fig. 2.1.4).

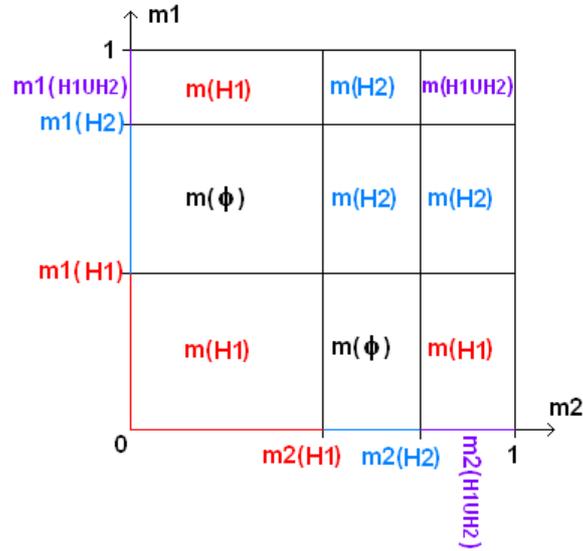


FIG. 2.1 – Présentation graphique de la fusion entre deux sources d'information m_1 et m_2 .

Cette règle de fusion a été critiquée dans plusieurs travaux [36, 37, 38], particulièrement dans le cas de deux sources en conflit total. Pour contourner ce problème, Dubois et Prade [39] ont défini l'opérateur de fusion disjonctif et conjonctif. Par la suite, d'autres

formes de combinaison ont été proposées de façon à déterminer tous les opérateurs de fusion pouvant être utilisés dans la théorie de l'évidence [40, 41].

La règle de *combinaison de Dempster* possède un élément neutre qui est la fonction d'ignorance totale :

$$m_1 \oplus m_2 = m_1 \quad \text{si} \quad m_2(\Omega) = 1 \quad (2.17)$$

On a aussi l'élément absorbant de la somme orthogonale qui est la fonction de certitude totale :

$$m_1 \oplus m_2 = m_2 \quad \text{si} \quad m_1(\{H_n\}) = 1 \quad (2.18)$$

De façon à faciliter le calcul de la combinaison, on peut utiliser la fonction de *communalité*. Dans ce cas, le résultat de la combinaison de Dempster m de deux fonctions m_1 et m_2 peut s'exprimer à l'aide de leurs fonctions de communalité respectives Q_1 et Q_2 par la relation suivante :

$$Q = Q_1 \cdot Q_2 \quad (2.19)$$

où :

$$Q(A) = \sum_{A \subseteq B} m(B) \quad \forall A \subseteq \Omega \quad (2.20)$$

La fonction de communalité vérifie les propriétés suivantes :

- $Q(\emptyset) = 1$
- $Q(\Omega) = m(\Omega)$

La communalité peut aussi s'exprimer en fonction de la crédibilité. Pour tout $A \subseteq \Omega$:

$$\begin{aligned} Q(A) &= \sum_{B \subseteq A} (-1)^{|B|} Bel(\bar{B}) \\ Bel(A) &= \sum_{B \subseteq \bar{A}} (-1)^{|B|} Q(B) \end{aligned} \quad (2.21)$$

où $|B|$ représente la cardinalité de l'élément B . Il est possible, à partir de la fonction de communalité, de revenir à une distribution de masse grâce à la transformée de Möbius :

$$m(A) = \sum_{A \subseteq B} (-1)^{|B-A|} Q(B) \quad (2.22)$$

Ainsi, on peut définir indifféremment une fonction de croyance à partir d'une distribution de masse, de plausibilité, de crédibilité et de communalité.

2.1.5 Conditionnement

La règle de combinaison de Dempster se déduit de la règle de conditionnement [36]. Le conditionnement consiste à réviser une croyance initiale m lorsqu'une proposition $A \subseteq \Omega$ est devenue vraie. On note $m(\cdot|A)$ le conditionnement de m par A . Le but du conditionnement est de définir la redistribution de la masse d'un sous ensemble $B \subseteq \Omega$. Le conditionnement d'une fonction m sur $A \subseteq \Omega$ définie dans le *monde fermé* donne la fonction de croyance conditionnelle $m(B|A)$ telle que :

$$m(B|A) = k \sum_{C \subseteq \bar{A}} m(B \cup C) \quad \forall B \subseteq A \quad (2.23)$$

$$m(B|A) = 0 \quad \forall B, \quad B \cap \bar{A} \neq \emptyset$$

avec :

$$k = \frac{1}{1 - \sum_{B \subseteq A} m(B)} \quad (2.24)$$

Ce conditionnement est aussi appelé règle de conditionnement de Dempster. La normalisation par le facteur k correspond à la redistribution de la masse incompatible avec A sur l'ensemble $B \subseteq A$. Idéalement, cette masse ne devrait pas exister car elle est en contradiction avec l'information nouvelle. Lorsque la masse de croyance accordée à l'élément inverse de A est égale à 1 ($Bel(A) = 1$), on ne peut pas appliquer la normalisation et le conditionnement n'est pas possible car l'information nouvelle est complètement incompatible avec les informations reçues précédemment. Les expressions de Plausibilité et de Crédibilité sont les suivantes :

$$Bel(B|A) = \frac{Bel(B \cup \bar{A}) - Bel(\bar{A})}{1 - Bel(\bar{A})} \quad (2.25)$$

$$Pl(B|A) = \frac{Pl(B \cup A)}{Pl(A)}$$

2.1.6 Choix du cadre de discernement

Dans le traitement d'un problème, il convient de choisir un cadre de discernement Ω adapté. De cette façon, on considère implicitement qu'au moins une des hypothèses incluses dans le cadre est solution du problème. Cependant, il se peut que le cadre de discernement ne contienne pas toutes les hypothèses éventuelles du problème. On doit alors choisir dans quel type de monde le cadre de discernement sera défini. Il existe trois

types de monde différents :

- **Monde fermé (Close world)** : c'est ce monde qui a été supposé précédemment pour la présentation de la théorie. Dans celui-ci, on suppose que le cadre de discernement est exhaustif et que, par conséquent, la solution figure dans le cadre. Comme toutes les hypothèses sont présentes, le jeu de masse est normalisé. En revanche, si on dispose de peu d'informations sur la possible solution du problème, il est alors nécessaire d'inclure une grande quantité d'hypothèses dans Ω . Le temps de calcul devient dans ce cas très important. Par ailleurs, si l'hypothèse solution ne figure pas dans l'ensemble de définition, la masse de conflit augmente mais est tout de même redistribuée sur les autres hypothèses à disposition.
- **Monde ouvert (Open world)** : cette fois ci, le nombre d'hypothèses de Ω n'est pas limité. Dans ce cas, si la masse sur l'ensemble vide devient trop importante, deux possibilités se dégagent. Soit on est en présence d'un conflit soit, l'hypothèse solution n'est pas incluse dans le cadre de discernement et il faut en chercher d'autres. Le problème du monde ouvert est de savoir déterminer à partir de quelle quantité de masse sur l'ensemble vide il ne s'agit plus d'un conflit mais d'une nouvelle hypothèse.
- **Monde ouvert étendu(Extended open world)** : ce monde combine les avantages des deux précédents. On choisit un nombre restreint d'hypothèses à mettre dans le cadre de discernement et on ajoute une hypothèse *. La masse sur l'ensemble vide représente le conflit entre les sources et elle est redistribuée sur les autres hypothèse. La masse sur * représente le fait que la bonne solution ne figure pas dans l'ensemble de définition Ω . C'est dans ce monde que nous avons effectué nos travaux présentés par la suite.

2.1.7 Décision

De manière classique, la prise de décision repose sur des outils développés dans le cadre de la théorie de la décision. Ces outils, pour la plupart d'entre eux, sont basés sur des préceptes de la théorie des probabilités. Ainsi, avant d'aborder la prise de décision dans le cadre de la théorie des fonctions de croyance, nous introduisons les problèmes de décision

dans le cadre des probabilités.

Dans le cadre probabiliste

Soit $\Omega = \{H_1, \dots, H_N\}$ l'ensemble des hypothèses possibles (état du monde, état du système). Soit x un vecteur L -dimensionnel appartenant à une classe inconnue.

On suppose que pour chacune des hypothèses $H_n \in \Omega$, le vecteur forme x est caractérisé par une densité de probabilité conditionnelle notée $f(x|H_n)$. Si l'on sait estimer ou si l'on connaît la probabilité *a priori* $P(H_n)$ de chacune des classes, alors la probabilité *a posteriori* $P(H_n|x)$ peut être obtenue à l'aide de la règle de Bayes :

$$P(H_n|x) = \frac{f(x|H_n)P(H_n)}{f(x)} \quad n = 1, \dots, N \quad (2.26)$$

avec :

$$f(x) = \sum_{n=1}^N f(x|H_n)P(H_n). \quad (2.27)$$

Dans l'équation (2.27), $f(x)$ représente la densité de probabilité non conditionnelle.

Soit x un vecteur appartenant à l'hypothèse $H_k \in \Omega$ inconnue et $\mathcal{A} = \{a_1, \dots, a_A\}$ un ensemble d'actions possibles. Une fonction de coût $\lambda : \mathcal{A} \times \Omega \rightarrow \mathbb{R}$ est définie de telle manière que $\lambda(a_i|H_n)$ représente le coût encouru si l'on choisit l'action a_i alors que la vraie classe est H_n [42]. Dans le cadre de la théorie Bayésienne de la décision, le critère de décision repose sur la minimisation du risque moyen. L'espérance mathématique du coût si l'on choisit l'action a_i est appelée risque conditionnel et noté $R(a_i|x)$. Ce risque est défini à l'aide des probabilités *a posteriori* et des fonctions de coûts par la relation suivante :

$$R(a_i|x) = \sum_{n=1}^N \lambda(a_i|H_n)P(H_n|x). \quad (2.28)$$

En notant D la fonction de décision, le risque moyen de décision R s'exprime alors par :

$$R = \int R(D(x)|x)f(x)dx. \quad (2.29)$$

La minimisation du risque moyen s'obtient en minimisant $R(D(x)|x)$ pour tout x , c'est-à-dire en choisissant l'action a_i dont le risque conditionnel est le plus faible. Nous obtenons alors :

$$D_B(x) = a_i \Leftrightarrow R(a_i|x) < R(a_j|x) \quad \forall j \neq i. \quad (2.30)$$

La fonction de décision D_B est appelée règle de décision de Bayes.

Coûts $\{0, 1\}$

Dans le domaine du diagnostic, les hypothèses du monde $\Omega = \{H_1, \dots, H_N\}$ sont souvent associées à l'ensemble des actions possibles. Dans ce cas, l'ensemble des actions \mathcal{A} est constitué de N éléments $\{a_1, \dots, a_N\}$ qui correspondent respectivement à l'affectation du vecteur x à chacune des hypothèses H_n de Ω . En règle générale, si aucune information n'est donnée pour la définition des coûts, on considère alors qu'aucune erreur d'affectation n'est plus dommageable qu'une autre. Dans ce cas, on peut alors définir les coûts de la manière suivante :

$$\lambda(a_k|H_k) = 0 \quad (2.31)$$

$$\lambda(a_i|H_k) = 1 \quad \forall i \in \{1, \dots, N\}, \quad i \neq k. \quad (2.32)$$

Le risque conditionnel obtenu à partir de ces poids peut alors s'écrire de la manière suivante :

$$\begin{aligned} R(a_i|x) &= \sum_{n=1}^N \lambda(a_i|H_n)P(H_n|x) \\ &= \sum_{n \neq i} P(H_n|x) \\ &= 1 - P(H_i|x). \end{aligned} \quad (2.33)$$

Dans ce cas, la règle de décision de Bayes revient à choisir l'hypothèse de plus grande probabilité *a posteriori* :

$$D_B(x) = a_i \Leftrightarrow P(H_i|x) = \max_{n=1, \dots, N} P(H_n|x). \quad (2.34)$$

Coûts $\{0, 1\}$ avec rejet

Chow [43] a proposé d'introduire une action supplémentaire a_0 dans \mathcal{A} . Cette action, appelée action de rejet, consiste à refuser de prendre une décision lorsque le risque de mauvaise classification est trop grand. Si l'on note λ_0 le coût associé à l'action a_0 , la règle de Bayes avec rejet s'écrit alors :

$$\begin{aligned} D(x) = a_0 & \quad \text{si} \quad \max_{n=1, \dots, N} P(H_n|x) < 1 - \lambda_0 \\ D(x) = a_i & \quad \text{si} \quad P(H_i|x) = \max_{n=1, \dots, N} P(H_n|x) \geq 1 - \lambda_0. \end{aligned} \quad (2.35)$$

Ainsi, plus λ_0 est petit plus la probabilité de rejet est importante, jusqu'au rejet total pour $\lambda_0 = 0$, où l'on ne commet plus aucune erreur, c'est-à-dire que l'on rejette systématiquement tout vecteur à classer. A l'inverse, lorsque $\lambda_0 \geq 1 - 1/N$ le rejet est impossible

puisqu'au moins l'une des probabilités *a posteriori* est supérieure à $1/N$. Cette règle de décision sépare l'espace de représentation en $N + 1$ régions de décision. Le rejet, ainsi introduit par Chow, est qualifié de rejet d'ambiguïté par Dubuisson [44] car la zone qui lui est attribuée dans l'espace de représentation se situe systématiquement entre les classes.

Dans certains cas, comme lorsque les vecteurs sont éloignés (ce qui peut traduire l'apparition d'une nouvelle classe), la notion de rejet d'ambiguïté n'est pas suffisante. Il faut alors introduire une nouvelle possibilité de rejet désignée par rejet de distance [44]. L'action associée à ce rejet est noté a_d . A partir des probabilités *a posteriori* et de la densité de probabilité, l'utilisation du rejet de distance nous amène à la règle de décision suivante :

$$\begin{aligned} D(x) &= a_d & \text{si } f(x) < \lambda_d \\ D(x) &= a_i & \text{si } f(x) \geq \lambda_d \text{ et } P(H_i|x) = \max_{n=1,\dots,N} P(H_n|x). \end{aligned} \quad (2.36)$$

La règle de décision incluant les deux types de rejet est définie de la manière suivante :

$$\begin{aligned} D(x) &= a_d & \text{si } f(x) < \lambda_d \\ D(x) &= a_0 & \text{si } f(x) \geq \lambda_d \text{ et } \max_{n=1,\dots,N} P(H_n|x) < 1 - \lambda_0 \\ D(x) &= a_i & \text{si } f(x) \geq \lambda_d \text{ et } P(H_i|x) = \max_{n=1,\dots,N} P(H_n|x) \geq 1 - \lambda_0. \end{aligned} \quad (2.37)$$

Cette dernière règle de décision sépare l'espace des caractéristiques \mathcal{X} en $N + 2$ régions.

Nous venons de présenter les principaux outils de décision dans le cadre probabiliste. Ainsi, afin de bénéficier au mieux des bases solides et des axiomes connus de la théorie de la décision, généralement, l'interprétation des fonctions de croyance se fait dans le cadre du *Modèle des Croyances Transférables* proposé par Smets [45].

Le Modèle des Croyances Transférables

Le modèle des croyances transférables proposé par Smets se différencie des autres interprétations par le cloisonnement existant entre la modélisation des connaissances et la prise de décision. En effet, au niveau *crédal* s'effectue la modélisation (partie statique) et la révision (partie dynamique) des connaissances en écartant toute approche probabiliste car seules les connaissances certaines sont prises en compte. La décision s'effectue au niveau dit *pignistique*², qui impose une transformation des fonctions de croyance. En effet, dans la théorie Bayésienne, décider à l'aide de connaissances incertaines revient à un *pari* sur

²Le terme *pignistique* a été introduit par Smets. Il provient du latin *pignus* signifiant pari.

l'hypothèse la plus probable [46]. Il est alors nécessaire de transformer les fonctions de croyance en distributions de probabilité. Le résultat de cette transformation est appelé *probabilité pignistique*. Ainsi, une fois cette transformation effectuée, nous pouvons utiliser l'ensemble des outils proposés dans le cadre de la théorie de la décision.

Probabilité pignistique : le principe de raison insuffisante

Soit m , une fonction de croyance synthétisant l'ensemble des connaissances à l'instant où la décision doit être prise. Le problème, qui se pose, peut être présenté de la manière suivante. Comment, afin d'utiliser la règle de décision de Bayes, peut-on transformer m en une distribution de probabilité ?

Smets [47] se base alors sur le principe de raison insuffisante. C'est-à-dire qu'en l'absence de raison de privilégier une hypothèse plus qu'une autre, on suppose que les hypothèses sont équi-probables. Ainsi, pour tout élément focal $A \in \mathcal{F}(m)$, la masse $m(A)$ sera redistribuée uniformément sur les éléments de A . On obtient alors une distribution de probabilité particulière dite probabilité pignistique et notée $BetP$. Cette probabilité est obtenue de la manière suivante :

$$BetP(H_n) = \sum_{A \subseteq \Omega} \frac{|H_n \cap A|}{|A|} m(A) \quad \forall H_n \in \Omega. \quad (2.38)$$

Ainsi, on associe une probabilité pignistique à une seule fonction de croyance. Inversement, on associe une infinité de fonctions de croyance à une distribution pignistique. Cela reflète la perte d'information occasionnée au passage entre le niveau crédal et le niveau pignistique. En effet, la transformation d'une fonction de croyance en distribution de probabilité s'accompagne de contraintes telles que :

- l'affectation d'une probabilité à chaque élément de Ω ,
- le respect du principe d'additivité.

Ces contraintes font perdre les avantages liés aux fonctions de croyance.

Une fois la distribution de probabilité construite, on utilise, de manière classique, la décision Bayésienne qui préconise l'action pour laquelle l'espérance du coût est la plus faible. Ainsi, on peut définir l'espérance pignistique d'une fonction $f : \Omega \rightarrow \mathbb{R}$ comme son espérance mathématique relativement à $BetP$:

$$E_{bet}(f) = \sum_{H_n \in \Omega} f(H_n) BetP(H_n). \quad (2.39)$$

Soit l'individu de vecteur forme x qui est à l'origine de la fonction de croyance m définie sur l'ensemble des hypothèses de Ω . Alors, de la même manière que dans le cadre de la théorie Bayésienne de la décision, nous pouvons définir $\mathcal{A} = \{a_1, \dots, a_N\}$ un ensemble de N actions possibles et une fonction de coût $\lambda : \mathcal{A} \times \Omega \rightarrow \mathbb{R}$ de telle manière que $\lambda(a_i|H_n)$ représente le coût encouru si l'on choisit l'action a_i alors que la vraie classe est H_n . Le risque conditionnel de décider a_i sachant x est défini par :

$$R_{Bet}(a_i|x) = \sum_{H_n \in \Omega} \lambda(a_i|H_n) BetP(H_n). \quad (2.40)$$

L'action $a \in \mathcal{A}$ qui minimise ce risque est celle qui sera retenue. Dans le cas de coûts $\{0, 1\}$, la minimisation du risque conditionnel revient à choisir l'hypothèse de plus grande probabilité pignistique. Notons, que les principes de coûts avec rejet, définis dans la décision Bayésienne, peuvent être utilisés comme règle de décision.

Autre règles de décision

Bien que seule la transformation des fonctions de croyance en probabilité pignistique et l'utilisation de la théorie de la décision Bayésienne aient été justifiées [48], d'autres principes de décision ont vu le jour.

Parmi eux, le maximum de crédibilité ou le maximum de plausibilité qui sélectionnent respectivement l'hypothèse la plus crédible et l'hypothèse la plus plausible. Ce dernier critère est préconisé dans [49]. Une étude sur le choix entre une décision basée sur la probabilité pignistique et sur le maximum de plausibilité est présentée dans [50].

De plus, de par l'interprétation probabiliste de la théorie des croyances, des risques conditionnels autres que celui associé à la probabilité pignistique peuvent être employés. En effet, la définition d'enveloppes inférieure et supérieure, respectivement représentées par la crédibilité et la plausibilité, pour encadrer la véritable probabilité aboutit à la construction de risques inférieur et supérieur. Ces risques, étudiés dans [51, 52], sont définis par :

$$R_*(a_i|x) = \sum_{A \subseteq \Omega} m(A) \min_{H_n \in A} \lambda(a_i|H_n) \quad (2.41)$$

$$R^*(a_i|x) = \sum_{A \subseteq \Omega} m(A) \max_{H_n \in A} \lambda(a_i|H_n). \quad (2.42)$$

L'équation (2.41) définit le risque inférieur. La minimisation de ce risque correspond à une stratégie "optimiste". L'équation (2.42) définit le risque supérieur. La minimisation de ce

risque correspond à une stratégie dite "pessimiste". La distribution pignistique étant une distribution particulière entre les enveloppes inférieure et supérieure, nous obtenons alors la relation d'inégalité suivante qui lie les équations (2.40), (2.41) et (2.42) :

$$R_*(a_i|X) \leq R_{Bet}(a_i|X) \leq R^*(a_i|X). \quad (2.43)$$

Dans le cas de coûts $\{0, 1\}$, la minimisation des risques inférieur et supérieur revient respectivement à une prise de décision basée soit sur le maximum de plausibilité soit sur le maximum de crédibilité.

Tous les critères de décision ont été définis de manière à prendre une décision sur une hypothèse simple, c'est-à-dire une hypothèse singleton H_n de l'ensemble Ω . Ceci est valable lorsqu'on souhaite prendre une décision qui soit précise. Malheureusement, il peut arriver que cette précision soit obtenue au détriment de la fiabilité de la décision. En effet, il peut parfois être préférable et plus prudent de choisir un ensemble d'hypothèses plutôt que choisir une hypothèse singleton. Il y a peu d'application où les critères autorisent les hypothèses composées [53]. Toutefois, si l'on s'autorise à prendre comme décision des hypothèses composées, quelques précautions doivent être prises. On peut utiliser les stratégies de décision définies précédemment, cependant les décisions seront toujours en faveur des hypothèses composées par rapport aux hypothèses singletons, car de manière générale, plus le cardinal de l'ensemble est grand, plus les fonctions de croyance sont importantes. Ceci mène donc à imposer des contraintes supplémentaires, comme le cardinal maximal de la solution, ou un seuil sur le critère de décision.

2.1.8 Mesures d'incertitude et de conflit

De part la nature de la théorie des fonctions de croyances, on peut distinguer deux fonctions différentes permettant la quantification de l'incertitude [54]. La première est appelée la non spécificité et est définie par la formule suivante :

$$N(m) = \sum_{A \subseteq \Omega} m(A) \cdot \log_2 |A| \quad (2.44)$$

où $|A|$ est la cardinalité de l'élément A . Il a été démontré que cette mesure, qui exprime l'incertitude sur la fonction de croyance m , est unique sous certaines conditions [55]. Elle varie de : $0 \leq N(m) \leq \log_2 |\Omega|$. $N(m) = 0$ quand $m(A) = 1$ ($A \subset \Omega$ et A est un singleton), on est dans le cas de la certitude totale. $N(m) = \log_2 |\Omega|$ quand $m(\Omega) = 1$ (ignorance totale).

Le second type de mesure est la discordance [56] :

$$D(m) = - \sum_{A \subset \Omega} m(A) \cdot \log_2 \left[1 - \sum_{B \subset \Omega} m(B) \cdot \frac{|B - A|}{|B|} \right] \quad (2.45)$$

Cette mesure exprime le conflit moyen (par la transformation logarithmique) au travers des différents corps d'évidence. La partie suivante :

$$\sum_{B \subset \Omega} m(B) \cdot \frac{|B - A|}{|B|} \quad (2.46)$$

exprime la somme des conflits individuels en correspondance avec un ensemble particulier A .

De façon à quantifier le conflit, il est possible d'utiliser l'entropie de Shannon. Cette mesure est normalement applicable uniquement dans le cadre des probabilités mais peut néanmoins être appliquée sur une fonction de croyance Bayésienne m . L'entropie se définit alors par :

$$S(m) = - \sum_{H_n \in \Omega} m(\{H_n\}) \log_2(m(\{H_n\})) \quad (2.47)$$

On peut aussi l'écrire sous la forme suivante :

$$S(m) = - \sum_{H_n \in \Omega} m(\{H_n\}) \log_2(1 - \text{Confl}_m(H_n)) \quad (2.48)$$

où :

$$\text{Confl}_m = \sum_{\substack{H_{n'} \in \Omega \\ H_{n'} \neq H_n}} m(\{H_{n'}\}) \quad (2.49)$$

Le terme $\text{Confl}_m(H_n)$ représente la croyance totale attribuée aux éléments focaux différents de l'élément focal H_n . Cette grandeur exprime toute la croyance en conflit total avec la masse soutenant l'hypothèse H_n . L'entropie de Shannon est une moyenne pondérée, par les masses de croyance, du conflit existant entre les différentes propositions d'une fonction de croyance Bayésienne.

Après cette introduction sur les notions de base de la théorie des fonctions de croyance, la section suivante présente les différentes méthodes de prédiction basées sur des méthodes de filtrage. Dans un premier temps, nous verrons le problème du filtrage d'un point de vue général. Puis, nous verrons des filtres optimaux, pour commencer le filtre de Kalman linéaire. Nous verrons ensuite, pour les modèles non linéaires, le filtre de Kalman étendu (EKF).

2.2 Filtrage

Le problème du filtrage [57] consiste à déterminer un estimateur de variables d'un système dynamique (variables d'états) sujet à des perturbations et observées partiellement. La modélisation de l'évolution dans le temps d'un processus Markovien $\{X\}_t$ à partir de son observation bruitée $\{Y\}_t$ est donnée par :

$$X_{t+1} = F_t(X_t, \pi_t) \quad (t \geq 0) \quad (2.50)$$

où F_t est une fonction déterministe (fonction de transition) caractérisant la dynamique et π_t est un bruit de dynamique de loi connue et dont les réalisations temporelles sont indépendantes. Le processus X_t est Markovien et son noyau de transition sera noté q_t . Dans le but de déterminer l'état du système, on est amené à construire une équation d'observation qui relie à des instants t l'observation Y_t à l'état courant X_t . Ces mesures sont entachées d'erreurs dues à l'imperfection du capteur de mesure. La suite des observations Y_t pour $t \geq 0$ est modélisée par l'équation suivante :

$$Y_t = H_t(X_t) + v_t \quad (2.51)$$

où H_t est la fonction d'observation connue et v_t est un bruit blanc Gaussien additif concernant la mesure. On cherche à déterminer l'état de X_t à partir d'observations bruitées de $X_k^t = X_k, X_{k+1}, \dots, X_t$. En considérant l'état du système à un instant τ et en se plaçant à l'instant t , on distingue :

- si $t > \tau$, il s'agit d'un problème de lissage
- si $t = \tau$, il s'agit d'un problème de filtrage,
- si $t < \tau$, il s'agit d'un problème de prédiction

Les hypothèses classiques du filtrage non-linéaire sont :

- les observations $\{Y_t, t \geq 1\}$ sont mutuellement indépendantes, conditionnellement à $\{X_t, t \geq 0\}$.
- le processus d'état X_t est Markovien et le bruit de mesure v_t est une séquence de variables aléatoires indépendantes identiquement distribuées (iid), indépendant du processus X_t .

- X_0 , l'état initial de densité p_0 est supposé de densité connue et indépendant de v_t et de w_t .

Le caractère optimal de l'estimateur \hat{X} de X dépend du critère à optimiser. Le problème d'estimation, dans le cas de l'estimateur à variance minimale, consiste donc à déterminer la mesure de probabilité conditionnelle aux observations $dP(X_0^t|Y_0^t)$ ou de manière particulière sa marginale $dP(X_t|Y_0^t)$. L'estimateur optimal de X_t sachant Y_0^t et noté \hat{X}_t s'écrit :

$$\hat{X}_t = E[X_t|Y_0^t] = \int_{X_t} X_t dP(X_t|Y_0^t) = \int_{X_0^t} X_t dP(X_0^t|Y_0^t) \quad (2.52)$$

Cet estimateur est non biaisé et de variance minimale. Dans le cas où la loi conditionnelle de X_t sachant les observations Y_0^t est multimodale, il peut être souhaitable de prendre comme estimateur le maximum *a posteriori* :

$$\hat{X}_t = \text{ArgMax}_{X_t}[dP(X_t|Y_0^t)] \quad (2.53)$$

2.2.1 Filtrage optimal

Le problème du filtrage étant dynamique, il est important de mettre en évidence des relations récursives permettant de calculer à chaque instant cette mesure de probabilité. On peut décomposer cette opération en deux parties :

- une partie prédictive fondée sur les équations de la dynamique (eq. 2.50), afin d'engendrer *a priori* la mesure de probabilité à l'instant t , connaissant les $t - 1$ dernières observations. La construction de cette mesure se fait grâce à l'équation de Chapman-Kolmogorov :

$$dP(X_{t+1}|Y_0^t) = \int_{X_t} dP(X_{t+1}|X_t)dP(X_t|Y_0^t) \quad (2.54)$$

où $dP(X_{t+1}|X_t)$ représente la probabilité de transition de l'état X_t à X_{t+1} .

- une partie corrective reposant sur la règle de Bayes :

$$dP(X_{t+1}|Y_0^{t+1}) = \frac{dP(Y_{t+1}|X_{t+1})}{dP(Y_{t+1}|Y_0^t)} dP(X_{t+1}|Y_0^t) \quad (2.55)$$

où $dP(Y_{t+1}|Y_0^t)$ est un terme de normalisation indépendant de X .

On peut alors réécrire $dP(X_0^t|Y_0^t)$ sous la forme :

$$dP(X_0^t|Y_0^t) = \frac{\prod_{\tau=0}^t dP(Y_\tau|X_\tau) \prod_{\tau=1}^t dP(X_\tau|X_{\tau-1})dP(X_0)}{\int_{X_0^t} \prod_{\tau=0}^t dP(Y_\tau|X_\tau) \prod_{\tau=1}^t dP(X_\tau|X_{\tau-1})dP(X_0)} \quad (2.56)$$

2.2.2 Filtre de Kalman Linéaire

Le filtre de Kalman est un outil essentiel pour les ingénieurs pour résoudre les problèmes de filtrage. Version moderne et probabiliste de la méthode des moindres carrés, le filtre de Kalman concerne essentiellement les systèmes linéaires. Le filtre fut développé par Kalman [58] en 1960 pour le cas discret et repris en 1961 par Kalman et Bucy pour le cas continu. On considère que le modèle est linéaire, avec un bruit additif Gaussien et l'observation est une fonction linéaire de l'état entachée d'un bruit additif Gaussien :

$$\begin{aligned} X_{t+1} &= F_t X_t + B_t + W_t \\ Y_t &= H_t X_t + V_t \end{aligned} \quad (2.57)$$

où

- F_t de dimension $(n \times n)$, B_t $(n \times 1)$ et H_t $(m \times n)$ sont des matrices déterministes et connues.
- les bruits d'état et d'observation W_t et V_t à valeurs dans \mathbb{R}^d et \mathbb{R}^m sont des bruits blancs Gaussiens de matrices de covariance respectives Q_t et R_t . Ces bruits sont mutuellement indépendants et indépendants de la condition initiale X_0 .
- la loi initiale X_0 est Gaussienne de moyenne $E[X_0] = \bar{X}_0$ et de matrice de covariance P_0 .

Et dans ce cas, on montre que le couple (X_1^t, Y_1^t) est Gaussien et que les lois conditionnelles dP_t sont elles aussi Gaussiennes. Le problème est de dimension finie. Deux paramètres suffisent à caractériser la densité dP_t : sa moyenne \hat{X}_t et sa matrice de covariance $P_{t|t}$. Ces paramètres sont calculés de manière récursive à partir des équations (2.57) suivant les étapes de prédiction et de correction du filtre de Kalman :

- Equations de prédiction :

$$\begin{aligned} \hat{X}_{t+1|t} &= F_t \hat{X}_{t|t} + B_t \\ P_{t+1|t} &= F_t P_{t|t} F_t^T + Q_t \end{aligned} \quad (2.58)$$

- Equations de correction :

$$\begin{aligned} K_{t+1|t} &= P_{t+1|t} H_t^T (H_t P_{t+1|t} H_t^T + R_t)^{-1} \\ P_{t+1|t} &= P_{t+1|t} - K_{t+1|t} H_t P_{t+1|t} \\ \hat{X}_{t|t} &= \hat{X}_{t+1|t} + K_{t+1|t} [Y_t - (H_t \hat{X}_{t+1|t})] \end{aligned} \quad (2.59)$$

où K_t est le gain de Kalman. On remarque que les matrices de covariance $(P_{t|t})$, $(P_{t+1|t})$ et le gain (K_t) pour $t \geq 0$ ne dépendent pas des observations Y_1^t . On peut donc les pré-

calculer afin de diminuer la quantité de calculs à effectuer en temps réel. On peut voir le filtre de Kalman de trois manières différentes :

- le filtre de Kalman est solution récursive du maximum de vraisemblance (moindres carrés récursifs).
- le filtre de Kalman résout les équations Bayésiennes.
- le filtre de Kalman est la projection du processus d'état sur l'espace des mesures de base orthonormale constituée par innovations $[Y_t - (H_t \hat{X}_{t+1|t})]$.

Il est intéressant de noter que, dans le cas de bruits non Gaussiens, et de modèles linéaires, le filtre de Kalman fournit l'estimée linéaire de l'état du système à variance minimale. Dans le cas où les coefficients dépendent des observations passées, le modèle est dit "conditionnellement Gaussien". Le processus (X_t, Y_t) n'est pas un processus Gaussien mais la loi conditionnelle dP_t reste Gaussienne et le filtre de Kalman fonctionne toujours.

2.2.3 Filtre de Kalman étendu

Cette fois ci, le système dynamique est non linéaire avec des bruits blancs Gaussiens additifs, indépendants entre eux et indépendants de la loi initiale :

$$\begin{aligned} X_{t+1} &= f_t(X_t) + W_t \\ Y_{t+1} &= h_t(X_t) + V_t \end{aligned} \tag{2.60}$$

si les fonctions f_t et h_t sont dérivables, on peut linéariser le système autour de l'état prédit $\hat{X}_{t+1|t}$ et autour de l'état courant \hat{X}_t .

$f_t(X) \approx F_t X + C_t$, avec $F_t = \nabla f_t(\hat{X}_{t-1})$, et $C_t = f_t(\hat{X}_{t-1}) - F_t \hat{X}_{t-1}$, $h_t(X) \approx H_t X + D_t$, avec $H_t = \nabla h_t(\hat{X}_t)$, et $D_t = h_t(\hat{X}_{t-1}) - H_t \hat{X}_{t-1}$. Le modèle linéarisé est alors le suivant :

$$\begin{aligned} X_{t+1} &= F_t X_t + C_t + W_t \\ Y_t &= H_t X_t + D_t + V_t \end{aligned} \tag{2.61}$$

Dans ce cas les matrices de covariance et de gain ne peuvent plus être calculées hors ligne car H_t et F_{t+1} sont fonction de l'état prédit, et de l'état courant.

Simple à mettre en œuvre, rapide en temps de calcul, le filtre de Kalman est un outil complet, il est utilisé couramment dans le domaine du filtrage. Des travaux récents de Getout-Petit [59] montrent que l'utilisation de l'EKF dans le cas d'un modèle d'état et d'observation en temps continu est justifiée lorsque le système est observable et lorsque le bruit d'observation et l'erreur initiale sont faibles. Cependant, l'EKF ne peut pas s'appliquer lorsque la densité conditionnelle est multi-modale.

2.3 Conclusion

Dans ce chapitre, nous avons présenté les outils qui seront utilisés par la suite dans ce mémoire. La théorie des fonctions de croyance offre l'avantage de modéliser d'une façon plus adaptée les informations incertaines. Le problème de représentation des fonctions de croyance a donné naissance à plusieurs interprétations [30, 60]. Parmi ces modèles, celui des croyances transférables proposé par Smets [36] repose sur une interprétation non probabiliste des croyances, qui est une généralisation de théories telles que la théorie des probabilités et la théorie des possibilités. La théorie des fonctions de croyance est la base de notre algorithme d'association présenté dans le chapitre suivant.

Nous avons aussi présenté dans ce chapitre différentes méthodes de filtrage prédictifs. Le filtrage de Kalman linéaire ne sera pas utilisé sur les données réelles étant donné ses mauvais résultats dans le cas de déplacements d'objets. Dans le cadre des méthodes de filtrage optimal, nous utiliserons le filtre de Kalman étendu (EKF), qui nous a donné de bons résultats.

Le chapitre 3 aborde le fonctionnement complet de l'algorithme pour la détection et le suivi d'objet, ainsi que la prédiction de l'évolution des trajectoires des objets suivis. La prédiction de la trajectoire des objets servira d'une part, à renforcer la détection et d'autre part, à déterminer si il y a danger ou non pour les occupants du véhicule.

Chapitre 3

Déroulement de l'algorithme

Pour un véhicule intelligent, les objets sont détectés au moyen des capteurs qui équipent ce véhicule. Nous connaissons déjà les capteurs qui seront utilisés dans le projet RaViOLi et nous connaissons donc la nature des informations qui seront délivrées par ces capteurs. Les informations des objets détectés nous seront transmises sous forme (distance;angle) : $(\rho; \Theta)$ par rapport aux capteurs. De plus, nous pourrions obtenir les dimensions apparentes des véhicules.

Le but est alors de suivre les objets et de prédire leur trajectoire. Le suivi implique de connaître l'objet à un instant $t - 1$ et de le retrouver parmi les objets détectés à l'instant t . Nous calculons donc des masses de croyances indiquant la relation qui existe entre deux objets d'un instant $t - 1$ à t . Chaque capteur fournissant sa propre liste d'objet (tous les capteurs ne détectent pas tous les mêmes objets), il y a ainsi deux jeux de masses par capteur, un basé sur l'information de distance et l'autre basé sur l'information d'angle, pour chaque relation entre les objets. Pour chaque capteur, on fusionne les jeux de masses issus de la distance avec ceux obtenus grâce à l'angle. Ensuite, on fusionne les masses entre les capteurs. A l'aide d'un algorithme d'association, nous déterminons quels sont les objets qui ont été suivis, ceux nouvellement apparus et ceux qui ont disparus. On calcule, pour les objets suivis et les nouveaux objets, la prédiction de la trajectoire pour deux instants différents. Une prédiction à $t + 1$ est rebouclée au niveau de la création des masses comme un capteur supplémentaire et intervient dans la fusion avec la mesure à l'instant $t + 1$. Une autre prédiction, à plus long terme, $t + n$ secondes, où n est calculé en fonction de la vitesse du véhicule, sert à déterminer si l'objet présente ou non un danger pour le véhicule. Elle permet ainsi d'établir une zone de confiance autour du véhicule

et de prévenir suffisamment à l'avance le chauffeur en cas de danger. L'algorithme est représenté sur la figure Fig. 3.1

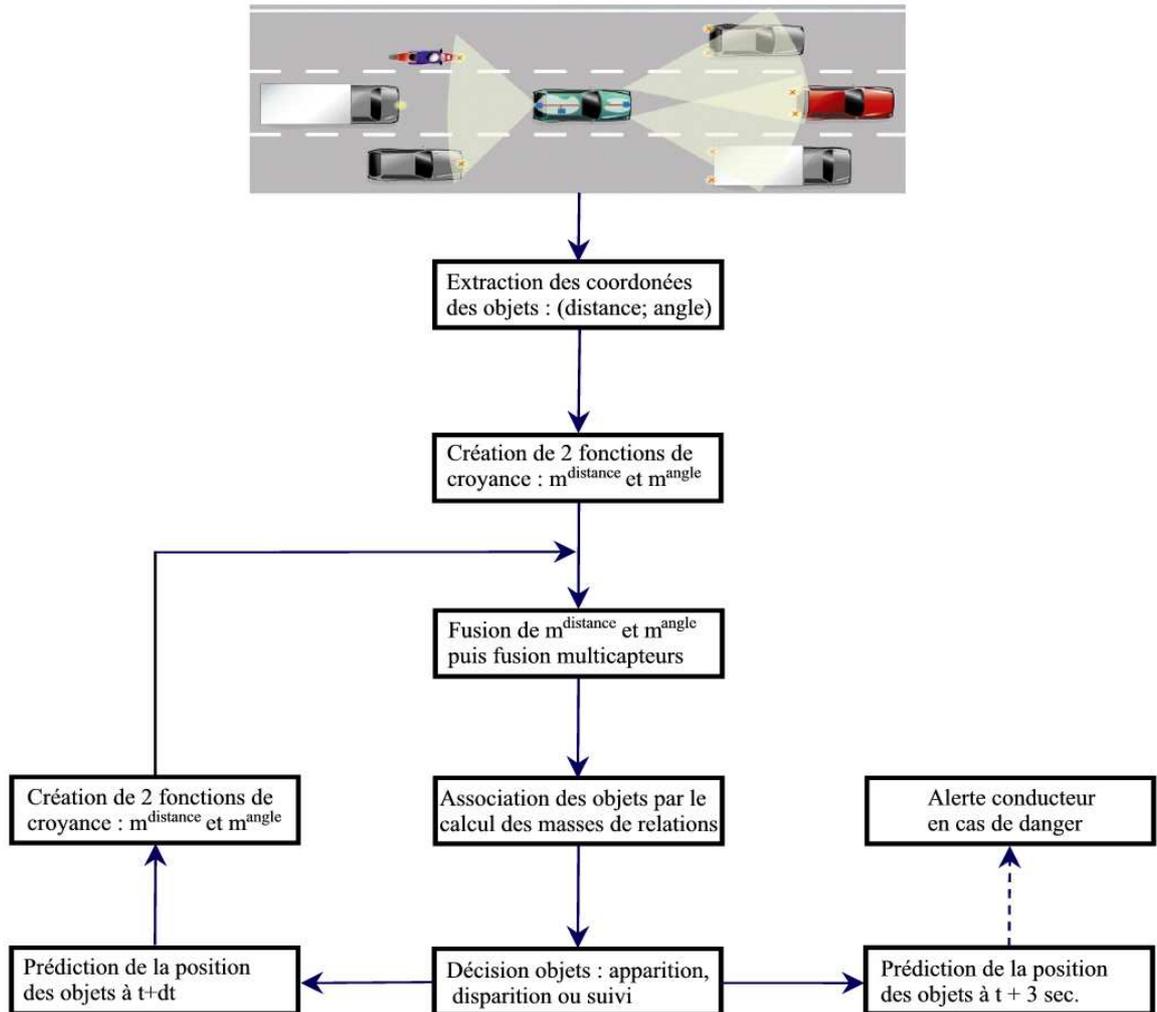


FIG. 3.1 – Déroulement de l'algorithme complet.

3.1 Création des masses

Dans cette section nous décrivons comment sont fabriquées les fonctions de croyance à partir des informations capteurs. Au niveau de la notation, X_i correspond aux objets perçus ($i = 1 : NbP$) à l'instant t et Y_j correspond aux objets connus ($j = 1 : NbC$). Les objets connus sont en fait des objets qui ont été perçus à l'instant précédent et que l'on a stocké dans une mémoire. Tout d'abord, nous avons défini le cadre de discernement dans lequel nous allons travailler. Il est composé de deux hypothèses : $\Omega_{i,j} = \{(X_iRY_j); (X_i\bar{R}Y_j)\}$. Soit l'objet perçu X_i correspond à un objet connu Y_j (ils sont alors en relation : (X_iRY_j)), soit il ne correspond à aucun des objets (pas de relation : $(X_i\bar{R}Y_j)$) [61].

Il existe plusieurs méthodes pour créer le jeu de masses de relation entre les objets [62]. Nous avons utilisé la formulation basée sur une fonction exponentielle introduite par Denoeux [63] :

$$\begin{aligned} m(X_i R Y_j) &= \alpha_0 \cdot \exp(-e_{i,j}^2) \\ m(X_i \bar{R} Y_j) &= \alpha_0 \cdot (1 - \exp(-e_{i,j}^2)) \\ m(\Omega_{i,j}) &= 1 - \alpha_0 \end{aligned} \quad (3.1)$$

avec $e_{i,j}$ l'écart existant entre deux informations (distances ou angles) provenant des objets perçus X_i et connus Y_j . α_0 est un coefficient qui caractérise la fiabilité du capteur d'où sont issues les informations. La valeur de α_0 est déterminée par la distance entre l'objet et le capteur ($d_{o,c}$), plus l'objet en est éloigné, plus le coefficient est faible (eq. 3.2).

$$\begin{aligned} \alpha_0 &= 0.9 - 0.003 * (d_{o,c} - 10) \quad \text{si } |d_{o,c}| < 150 \\ \alpha_0 &= 0 \quad \text{si } |d_{o,c}| > 150 \end{aligned} \quad (3.2)$$

Son maximum est de 0.9 lorsque l'objet détecté est à une distance inférieure à 10m puis, la valeur de α_0 chute linéairement avec la distance pour atteindre 0.48 à 150m (Fig. 3.2). Au delà de 150m, α_0 est nul de façon à ne pas utiliser des informations non fiables.

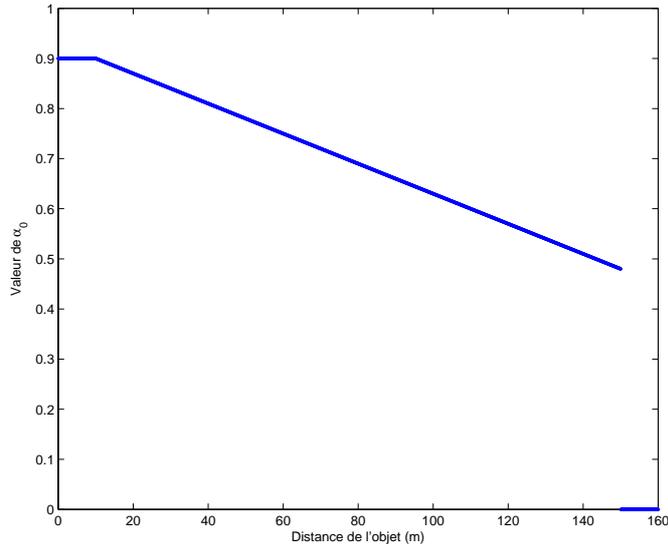


FIG. 3.2 – Evolution du coefficient d'affaiblissement α_0 en fonction de la distance de l'objet détecté.

Il y a alors un jeu de masse pour la distance (Fig. 3.3) et un pour l'angle et ce pour

chaque capteur.

Ensuite, il suffit de fusionner pour chaque capteur les jeux de masses de distance et d'angle, puis de fusionner entre les différents capteurs. La fusion est effectuée en utilisant l'opérateur conjonctif de Dempster avec normalisation du jeu de masses (Sec. 2.1.4).

Nous avons donc à l'issue de la fusion autant de jeu de masses que de relations existantes entre les différents objets connus et perçus. La section suivante présente l'algorithme d'association qui permet de décider quels sont les objets qui ont été suivis, quels sont ceux qui sont apparus et ceux qui ont disparu.

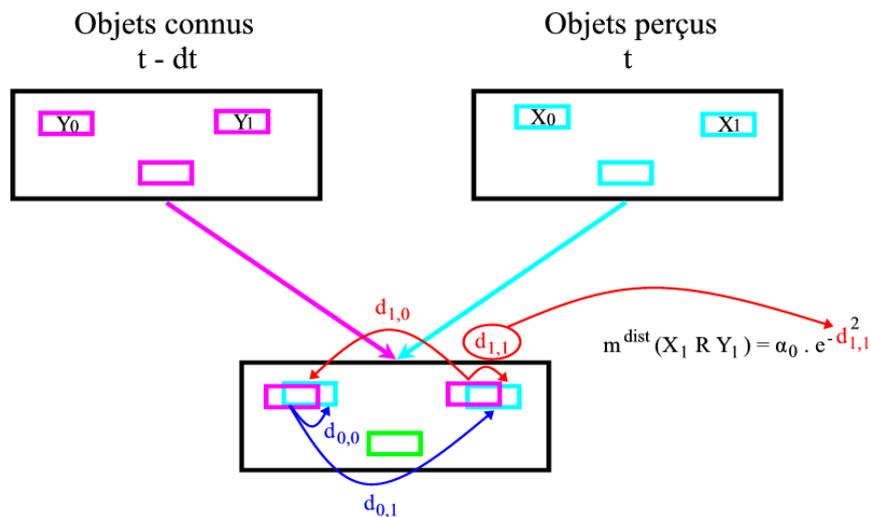


FIG. 3.3 – Association entre les objets perçus et connus à partir de l'information de distance.

3.2 Association d'objets

Cette section décrit le fonctionnement d'un algorithme de fusion pour l'association des objets. L'algorithme que nous avons repris à été développé par M. Rombaut [64] et amélioré par D. Gruyer [6].

3.2.1 Formalisme mathématique

Nous disposons donc de deux listes d'objets : les objets perçus (X_i) et les objets connus (Y_j). La mise en correspondance consiste alors à trouver parmi les objets perçus lesquels correspondent aux objets connus. On sait aussi que pour cette association un seul objet perçu X_i ne peut correspondre qu'à un seul objet connu Y_j et inversement.

L'objet pouvant apparaître ou disparaître, on notera ces objets comme étant en relation avec "*", ce qui signifiera "en relation avec aucun des objets". Ainsi, si un objet perçu X_i ne peut être associé à un des objets connus Y_j , alors il s'agit d'un objet nouvellement apparu : $(X_i R^*)$. A l'inverse, si un objet connu Y_j n'est associé avec aucun des objets perçus, alors cet objet a disparu (il peut être masqué par un autre objet, hors de la portée des capteurs, ...) : $(Y_j R^*)$. L'association s'effectue par l'intermédiaire du calcul de deux jeux de masses. Un premier, noté $m_{i..}$, qui correspond aux masses de relation d'un objet X_i perçu par rapport à tous les autres Y_j connus. Le second, est obtenu par l'opération inverse qui consiste à calculer la relation entre un objet Y_j connu par rapport à tous les X_i perçus. La fonction $m_{i..}$ est définie de la façon suivante sur le cadre $\Omega_{i..} = \{(X_i RY_0), (X_i RY_1), \dots, (X_i RY_{NbC}), (X_i R^*)\}$:

$$\begin{aligned}
 m_{i..}(X_i RY_j) &= K_{i..} \cdot m_{i,j}(X_i RY_j) \cdot \prod_{\substack{k=1 \\ k \neq j}}^{NbC} (1 - m_{i,k}(X_i RY_k)) \\
 m_{i..}(X_i R^*) &= K_{i..} \cdot \prod_{j=1}^{NbC} m_{i,j}(X_i \bar{R}Y_j) \\
 m_{i..}(\Omega_{i..}) &= K_{i..} \cdot \left[\prod_{j=1}^{NbC} (m_{i,j}(\Omega_{i,j}) + m_{i,j}(X_i \bar{R}Y_j)) - \prod_{j=1}^{NbC} m_{i,j}(X_i \bar{R}Y_j) \right] \\
 K_{i..} &= \frac{1}{\left(\prod_{j=1}^{NbC} (1 - m_{i,j}(X_i RY_j)) \right) \cdot \left(1 + \sum_{j=1}^{NbC} \left(\frac{m_{i,j}(X_i RY_j)}{1 - m_{i,j}(X_i RY_j)} \right) \right)}
 \end{aligned} \tag{3.3}$$

La fonction $m_{.j}$ est définie sur le cadre $\Omega_{.j} = \{(Y_j RX_0), (Y_j RX_1), \dots, (Y_j RX_{NbP}), (Y_j R^*)\}$:

$$\begin{aligned}
 m_{.j}(Y_j RX_i) &= K_{.j} \cdot m_{i,j}(X_i RY_j) \cdot \prod_{\substack{k=1 \\ k \neq i}}^{NbP} (1 - m_{k,j}(X_k RY_j)) \\
 m_{.j}(Y_j R^*) &= K_{.j} \cdot \prod_{i=1}^{NbP} m_{i,j}(X_i \bar{R}Y_j) \\
 m_{.j}(\Omega_{.j}) &= K_{.j} \cdot \left[\prod_{i=1}^{NbP} (m_{i,j}(\Omega_{i,j}) + m_{i,j}(X_i \bar{R}Y_j)) - \prod_{i=1}^{NbP} m_{i,j}(X_i \bar{R}Y_j) \right] \\
 K_{.j} &= \frac{1}{\left(\prod_{i=1}^{NbP} (1 - m_{i,j}(X_i RY_j)) \right) \cdot \left(1 + \sum_{i=1}^{NbP} \left(\frac{m_{i,j}(X_i RY_j)}{1 - m_{i,j}(X_i RY_j)} \right) \right)}
 \end{aligned} \tag{3.4}$$

On peut remarquer dans ces jeux de masses que la non relation n'apparaît plus comme hypothèse dans Ω . En fait, cette information n'est pas utile pour la décision puisque

décider que X_i n'est pas en relation avec Y_j ne donne aucune information sur la possible association des deux objets avec d'autres.

La décision finale concernant l'association est prise en utilisant les deux jeux de masses. On regroupe les valeurs de masses dans deux tableaux, l'un donnant la relation des X_i par rapport aux Y_j en utilisant les masses des fonctions $m_{i..}$, l'autre donnant l'inverse à partir des jeux de masses $m_{.j}$. On conserve les couples dont la masse est maximale dans les deux tableaux^(1).

3.2.2 Nouvelles Formules

Nous avons testé cet algorithme d'association et nous nous sommes aperçus que dans certaines situations, les décisions prises ne correspondaient pas aux résultats attendus. Le problème provient des masses $m_{i,j}(X_i\bar{R}Y_j)$, qui sont ajoutées sur les masses $m_{i..}(\Omega_{i..})$ et $m_{.j}(\Omega_{.j})$. Si du point de vue de la logique, dire que X_i n'est pas en relation avec Y_j ne pose pas de problème, cela n'apporte rien de plus sur la décision. En revanche, le fait d'ajouter cette masse sur Ω provoque une augmentation rapide de la croyance sur cette proposition. La prise de décision étant basé sur un critère de rejet de distance, il est alors possible de rejeter la décision. En prenant comme exemple un objet perçu et deux objets connus avec les distributions de croyance suivantes :

$$\begin{aligned} m_{1,1}(X_1RY_1) &= 0.2 & m_{1,2}(X_1RY_2) &= 0.45 \\ m_{1,1}(X_1\bar{R}Y_1) &= 0.45 & m_{1,2}(X_1\bar{R}Y_2) &= 0.15 \\ m_{1,1}(\Omega_{1,1}) &= 0.35 & m_{1,2}(\Omega_{1,2}) &= 0.4 \end{aligned}$$

nous obtenons après fusion :

Du tableau des masses $m_{i..}$ (Tab. 3.1), nous pouvons déduire que l'on ne connaît pas de relation avec X_1 : $m_{1..}(\Omega_{1..}) = 0.41$ tout en remarquant qu'une masse de relation a une valeur sensiblement identique mais inférieure $m_{1..}(X_1RY_2) = 0.396$. Des masses $m_{.j}$ (Tab. 3.1), on peut décider que Y_1 a disparu et que Y_2 est en relation avec X_1 . Les deux matrices donnent des résultats différents concernant X_1 , on ne peut donc pas décider. Dans un tel cas, une première solution a été proposée par M. Rombaut [64], qui consistait à recalcu-

¹Étant donné que l'algorithme d'association n'attribue de la masse que sur des singletons, on obtient la même décision que l'on utilise les critères de maximum de crédibilité ou de plausibilité ou encore le maximum de masse.

	X_1
Y_1	0.121
Y_2	0.396
*	0.073
$\Omega_{1,.}$	0.41

 $m_{i,.} =$

	X_1	*	$\Omega_{.,j}$
Y_1	0.2	0.45	0.35
Y_2	0.45	0.15	0.4

 $m_{.,j} =$
TAB. 3.1 – Tableaux des fonctions $m_{i,.}$ et $m_{.,j}$.

ler les fonctions $m_{i,.}$ et $m_{.,j}$ en comparant les deux hypothèses en conflit. Ici, cette méthode ne peut s'appliquer étant donné qu'il n'y a qu'un seul objet X_i . De plus, ce calcul est difficile à mettre en œuvre dès l'instant où il y a beaucoup d'objets. Nous avons donc décidé de modifier les équations permettant de calculer les jeux de masses $m_{i,.}$ et $m_{.,j}$. Tout d'abord, nous avons pris un cadre de discernement fixe. En effet, avec les formules de M. Rombaut, nous avons au départ : $\Omega_{i,j} = \{(X_i RY_j), (X_i \overline{R}Y_j)\}$, puis en effectuant l'algorithme d'association, le cadre devient : $\Omega_{i,.} = \{(X_i RY_1), (X_i RY_2), \dots, (X_i RY_{NbC}), (X_i R*)\}$. Nous avons donc choisi comme cadre unique $\Omega_{i,.}$ de la création des masses jusqu'à l'association. Ce choix entraîne une légère modification des hypothèses de départ. En effet, dans ce cas, $(X_i \overline{R}Y_j)$ est remplacé par $(\overline{X_i RY_j}) = [\bigcup_{\substack{k=1 \\ k \neq j}}^{NbC} (X_i RY_k)] \cup (X_i R*)$. Avec ce changement, il n'y a plus de transformation du cadre de discernement au cours de l'algorithme. Ensuite, l'accroissement trop rapide de $m_{i,.}(\Omega_{i,.})$ et $m_{.,j}(\Omega_{.,j})$ est solutionné par une répartition de la masse sur les hypothèses $(X_i RY_j)$ et $*$. Cette répartition repose sur le principe de raison insuffisante en distribuant la masse de non relation $(\overline{X_i RY_k})_{(k \neq j)}$ sur les hypothèses

qu'elle ne contredit pas (Cf. Annexe). La masse $m_{i,\cdot}$ est alors définie comme suit :

$$\begin{aligned}
 m_{i,\cdot}(X_i RY_j) &= K_{i,\cdot} \cdot [m_{i,j}(X_i RY_j) \cdot \prod_{\substack{k=1 \\ k \neq j}}^{NbC} (1 - m_{i,k}(X_i RY_k)) + \sum_{\substack{k=1 \\ k \neq j}}^{NbC} \frac{1}{NbC} \\
 &\quad \cdot m_{i,k}(\overline{X_i RY_k}) \cdot \prod_{\substack{p=1 \\ p \neq k}}^{NbC} m_{i,p}(\Omega_{i,\cdot}) + \sum_{\substack{k=1 \\ k \neq j}}^{NbC-1} \sum_{\substack{l>k \\ l \neq j}}^{NbC} \frac{1}{NbC-1} \cdot m_{i,k}(\overline{X_i RY_k}) \\
 &\quad \cdot m_{i,l}(\overline{X_i RY_l}) \cdot \prod_{\substack{p=1 \\ p \neq k, p \neq l}}^{NbC} m_{i,p}(\Omega_{i,\cdot}) + \cdots + \frac{1}{2} \cdot m_{i,j}(\Omega_{i,\cdot}) \cdot \\
 &\quad \prod_{\substack{p=1 \\ p \neq j}}^{NbC} m_{i,p}(\overline{X_i RY_p})] \\
 m_{i,\cdot}(X_i R*) &= K_{i,\cdot} \cdot [\prod_{j=1}^{NbC} m_{i,j}(\overline{X_i RY_j}) + \sum_{k=1}^{NbC} \frac{1}{NbC} \cdot m_{i,k}(\overline{X_i RY_k}) \cdot \\
 &\quad \prod_{\substack{p=1 \\ p \neq k}}^{NbC} m_{i,p}(\Omega_{i,\cdot}) + \sum_{k=1}^{NbC-1} \sum_{l>k}^{NbC} \frac{1}{NbC-1} \cdot m_{i,k}(\overline{X_i RY_k}) \cdot m_{i,l}(\overline{X_i RY_l}) \cdot \\
 &\quad \prod_{\substack{p=1 \\ p \neq k, p \neq l}}^{NbC} m_{i,p}(\Omega_{i,\cdot}) + \cdots + \sum_{j=1}^{NbC} \frac{1}{2} \cdot m_{i,j}(\Omega_{i,\cdot}) \cdot \prod_{\substack{p=1 \\ p \neq j}}^{NbC} m_{i,p}(\overline{X_i RY_p})] \\
 m_{i,\cdot}(\Omega_{i,\cdot}) &= K_{i,\cdot} \cdot \prod_{j=1}^{NbC} m_{i,j}(\Omega_{i,\cdot}) \\
 K_{i,\cdot} &= \frac{1}{(\prod_{j=1}^{NbC} (1 - m_{i,j}(X_i RY_j))) \cdot (1 + \sum_{j=1}^{NbC} (\frac{m_{i,j}(X_i RY_j)}{1 - m_{i,j}(X_i RY_j)})})}
 \end{aligned} \tag{3.5}$$

et la masse $m_{.,j}$:

$$\begin{aligned}
 m_{.,j}(Y_j R X_i) &= K_{.,j} \cdot [m_{i,j}(X_i R Y_j) \cdot \prod_{\substack{k=1 \\ k \neq i}}^{NbP} (1 - m_{k,j}(X_k R Y_j)) + \sum_{\substack{k=1 \\ k \neq i}}^{NbP} \frac{1}{NbP} \\
 &\cdot m_{k,j}(\overline{X_k R Y_j}) \cdot \prod_{\substack{p=1 \\ p \neq k}}^{NbP} m_{p,j}(\Omega_{.,j}) + \sum_{\substack{k=1 \\ k \neq i}}^{NbP-1} \sum_{\substack{l>k \\ l \neq i}}^{NbP} \frac{1}{NbP-1} \cdot m_{k,j}(\overline{X_k R Y_j}) \\
 &\cdot m_{l,j}(\overline{X_l R Y_j}) \cdot \prod_{\substack{p=1 \\ p \neq k, p \neq l}}^{NbP} m_{p,j}(\Omega_{.,j}) + \dots + \frac{1}{2} \cdot m_{i,j}(\Omega_{.,j}) \cdot \\
 &\prod_{\substack{p=1 \\ p \neq i}}^{NbP} m_{p,j}(\overline{X_p R Y_j})] \\
 m_{.,j}(Y_j R *) &= K_{.,j} \cdot [\prod_{i=1}^{NbP} m_{i,j}(\overline{X_i R Y_j}) + \sum_{k=1}^{NbP} \frac{1}{NbP} \cdot m_{k,j}(\overline{X_k R Y_j}) \cdot \\
 &\prod_{\substack{p=1 \\ p \neq k}}^{NbP} m_{p,j}(\Omega_{.,j}) + \sum_{k=1}^{NbP-1} \sum_{l>k}^{NbP} \frac{1}{NbP-1} \cdot m_{k,j}(\overline{X_k R Y_j}) \cdot m_{l,j}(\overline{X_l R Y_j}) \cdot \\
 &\prod_{\substack{p=1 \\ p \neq k, p \neq l}}^{NbP} m_{p,j}(\Omega_{.,j}) + \dots + \sum_{i=1}^{NbP} \frac{1}{2} \cdot m_{i,j}(\Omega_{.,j}) \cdot \prod_{\substack{p=1 \\ p \neq i}}^{NbP} m_{p,j}(\overline{X_p R Y_j})] \\
 m_{.,j}(\Omega_{.,j}) &= K_{.,j} \cdot \prod_{i=1}^{NbP} m_{i,j}(\Omega_{.,j}) \\
 K_{.,j} &= \frac{1}{(\prod_{i=1}^{NbP} (1 - m_{i,j}(X_i R Y_j))) \cdot (1 + \sum_{i=1}^{NbP} \frac{m_{i,j}(X_i R Y_j)}{1 - m_{i,j}(X_i R Y_j)})}
 \end{aligned} \tag{3.6}$$

Dans ces nouvelles relations, de nouveaux termes apparaissent : $(\frac{1}{NbC}, \dots, \frac{1}{2})$ dans la fonction $m_{i.,}$ et $(\frac{1}{NbP}, \dots, \frac{1}{2})$ dans la fonction $m_{.,j}$. Ils représentent la distribution équitable de la masse (principe de raison insuffisante) lorsqu'il y a plus d'une masse sur Ω multipliée par les masses de non relation. En effet, si on prend comme exemple un objet perçu et deux objets connus, si on multiplie $m_{1,2}(\overline{X_1 R Y_2})$ par $m_{1,1}(\Omega_{1,1})$, cela signifie que nous sommes certain que X_1 n'est pas en relation avec Y_2 , et, comme le cadre de discernement est exhaustif et clos, ce produit de masse se répartit entre $m_{1,1}(X_1 R Y_1)$ et $m_{1,1}(X_1 R *)$ (une moitié sur chacune des deux hypothèses $\frac{1}{2}$). Dans le cas de trois objets connus, avec deux masses sur Ω composant le produit $(m_{1,1}(\overline{X_1 R Y_1}) \cdot m_{1,2}(\Omega_{1,2}) \cdot m_{1,3}(\Omega_{1,3}))$, on affecte $\frac{1}{3}$ à la première relation $(m_{1,1}(X_1 R Y_2))$, $\frac{1}{3}$ à la seconde $(m_{1,1}(X_1 R Y_3))$ et $\frac{1}{3}$ sur $*$ $(m_{1,1}(X_1 R *))$, et ainsi de suite jusqu'à ce que l'on divise par NbC (ou NbP). Si maintenant, on reprend l'exemple précédent avec les nouvelles formules, nous obtenons les résultats présentés dans le tableau (Tab. 3.2).

	X_1
Y_1	0.15
Y_2	0.495
*	0.201
$\Omega_{1,}$	0.154

 $m_{i,} =$

	X_1	*	$\Omega_{,j}$
Y_1	0.2	0.45	0.35
Y_2	0.45	0.15	0.4

 $m_{,j} =$
TAB. 3.2 – Tableaux des fonctions $m_{i,}$ et $m_{,j}$.

Après étude de ces résultats, on peut voir qu'il n'y a pas d'ambiguïté sur la bonne décision qui est : (X_1RY_2) et Y_1 a disparu.

La section suivante montre un comparatif entre les deux algorithmes en utilisant des données synthétiques de façon à faire apparaître les limites de fonctionnement des deux formulations.

3.2.3 Comparaison entre les deux algorithmes

Le but de cette partie est de valider les formules d'association que nous avons présentées à partir de données synthétiques. Dans un premier temps, nous montrons l'utilisation des formules⁽²⁾ avec des données fiables, puis, dans la seconde partie, les données seront très incertaines.

Utilisation sur des données fiables

Dans cette partie, les données ont été créées d'une manière artificielle de sorte que l'incertitude sur les mesures reste inférieure à 20% ($\alpha \geq 0.8$). Pour simplifier les explications, nous ne présentons pas les tableaux de masses $m_{i,}$ et $m_{,j}$ mais seulement les masses qui sont nécessaires pour prendre la décision puisque nous connaissons par avance le résultat. Dans un premier temps, nous avons défini une trajectoire pour les objets (Fig. 3.4). Le premier objet évolue selon une équation dynamique fonction de l'accélération (que nous avons choisi proche de 0) et de la vitesse. La dynamique de l'autre objet est définie par une équation mathématique de type sigmoïde. Les deux objets se déplacent pendant 10s

²Pour faciliter la programmation des formules, sachant que la plupart des langages commencent à numérotter les indices à partir de 0, par la suite, i variera de 0 à $NbP - 1$, et j de 0 à $NbC - 1$

(l'échantillonnage est de 0.1s) selon les équations suivantes :

$$\begin{aligned} \text{Objet 0} &\rightarrow d = \frac{1}{2} \cdot 0.1 \cdot t^2 + 5 \cdot t + 19.3 \\ \text{Objet 1} &\rightarrow d = \frac{45}{1 + \exp(-2 \cdot t + 10)} + 10 \end{aligned} \quad (3.7)$$

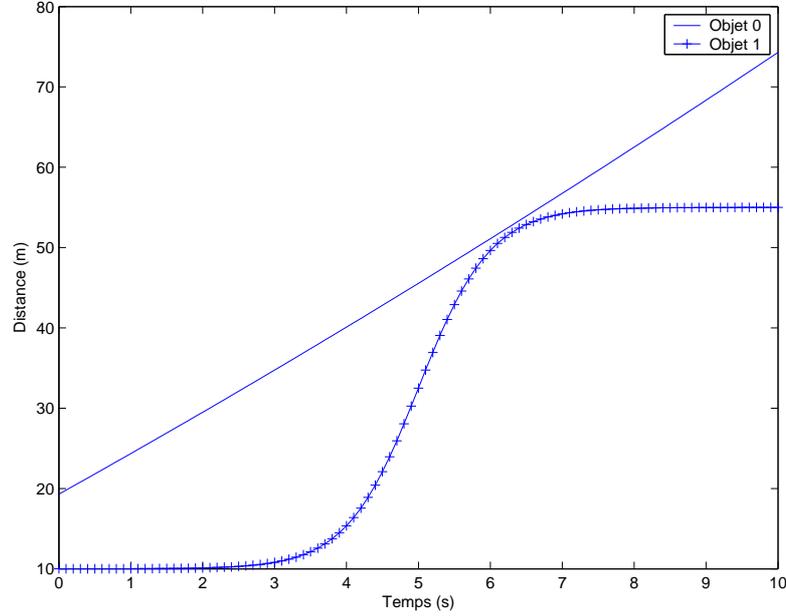


FIG. 3.4 – Evolution de la distance des objets pendant 10s par rapport au capteur.

Ces équations (Eq. 3.7) permettent d'introduire des contraintes sur le mouvement des véhicules tout en restant réalistes. De ces données, on calcule les inter-distances entre les objets perçus et connus (Section 3.1) à chaque pas d'échantillonnage, ce qui permet de tracer l'évolution de la masse de relation entre un objet perçu et les deux objets connus (Fig. 3.5).

Comme les objets ne sont pas très éloignés du capteur, nous avons choisi comme fiabilité pour les données : $\alpha_0 = 0.8$ pour l'objet 0 et $\alpha_1 = 0.8$ pour l'objet 1. Comme on peut le voir, les objets sont bien séparés au début, puis ils se rapprochent ($5.8s < t < 6.8s$). Dans cet intervalle, $m_{0,1}(X_0\bar{R}Y_1)$ décroît alors que $m_{0,1}(X_0RY_1)$ augmente. Cependant, $m_{0,1}(X_0\bar{R}Y_1)$ reste supérieure à $m_{0,1}(X_0RY_1)$.

La figure Fig. 3.6 montre l'évolution de la masse d'association en utilisant les formules de M. Rombaut. Comme on peut le constater, lorsque la fiabilité des données est bonne, ces formules donnent de très bons résultats.

On peut remarquer sur la figure Fig. 3.7 que les formules que nous avons modifiées produisent elles aussi de très bons résultats. On peut voir sur la masse de $m_{0,1}(\Omega_{0,1})$ (Fig. 3.7) qu'il y a une variation brusque de masse. Cette variation ne provient pas des

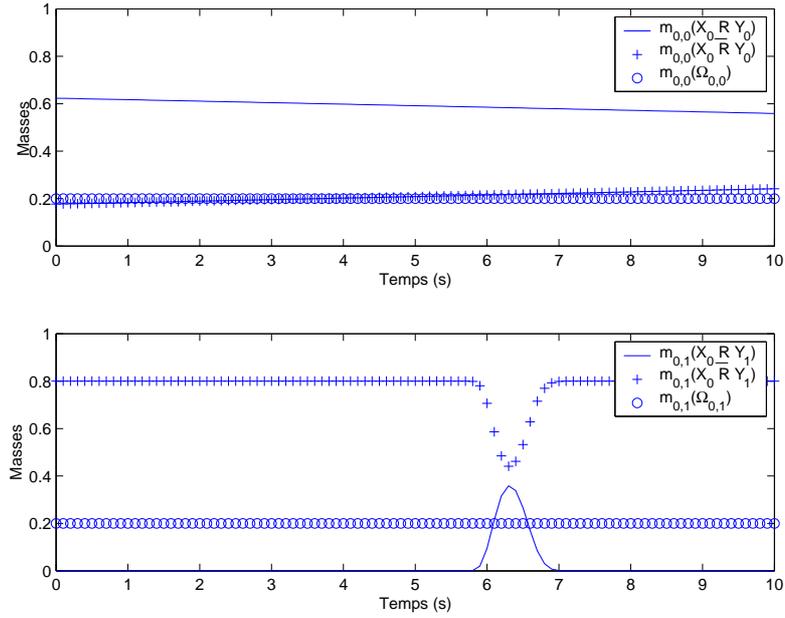
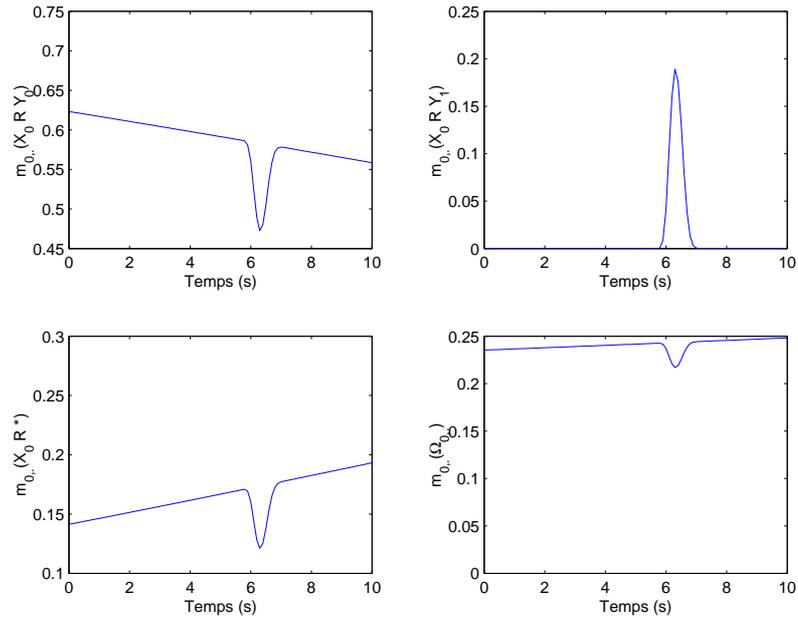

 FIG. 3.5 – Evolution de la masse de relation entre X_0 et Y_0 , X_0 et Y_1 .


FIG. 3.6 – Association en utilisant les formules de M. Rombaut.

masses $m_{i,j}(\Omega_{i,.})$ et $m_{i,j}(\Omega_{.,j})$ (ces masses sont constantes au cours du temps (Fig. 3.5)) mais de la variation du coefficient de conflit.

Maintenant, nous allons décrire comment se comportent les deux formulations lorsque l'on diminue la fiabilité des données.

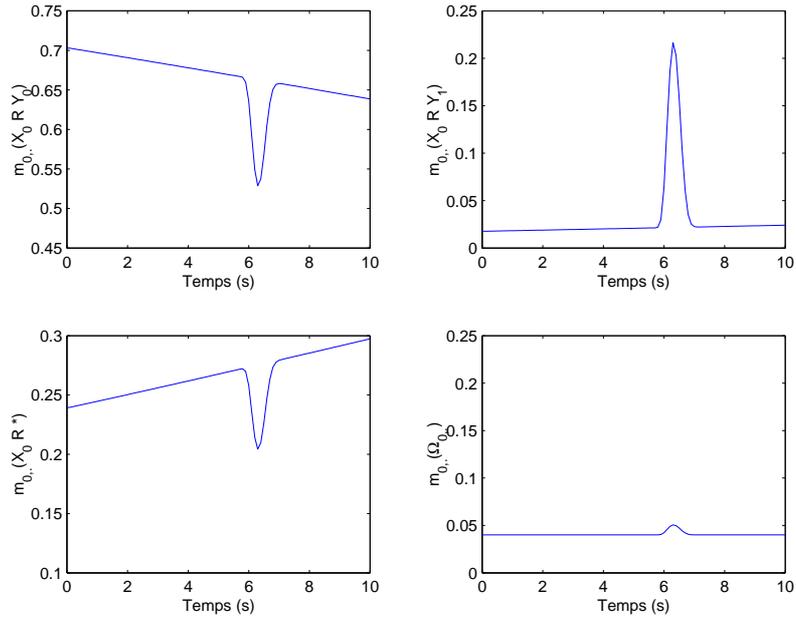


FIG. 3.7 – Association en utilisant les formules modifiées.

Association avec des données incertaines

Cette fois ci, la trajectoire des objets (Fig. 3.8) est définie par les équations suivantes :

$$\begin{aligned} \text{Objet 0} &\rightarrow d = \frac{1}{2} \cdot 0.1 \cdot t^2 + 5 \cdot t + 59.3 \\ \text{Objet 1} &\rightarrow d = \frac{45}{1 + \exp(-2 \cdot t + 10)} + 50 \end{aligned} \quad (3.8)$$

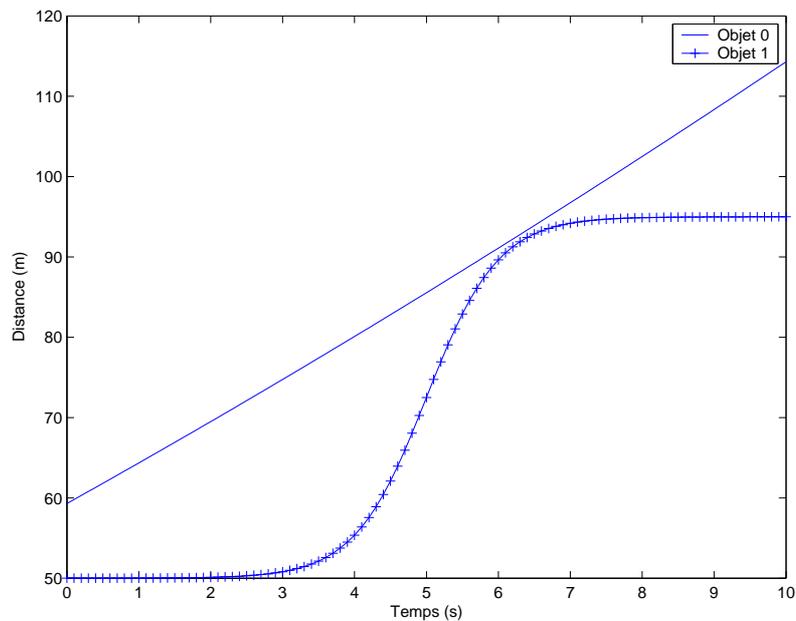


FIG. 3.8 – Evolution de la distance des objets, par rapport au capteur, pendant 10s.

Pour cette simulation, la distance est supérieure à 50m, et donc nous avons fixé des

coefficients de fiabilité plus faible : $\alpha_0 = 0.6$ et $\alpha_1 = 0.7$. L'évolution des masses de relation entre l'objet X_0 et Y_0 et Y_1 est représentée sur la figure Fig. 3.9.

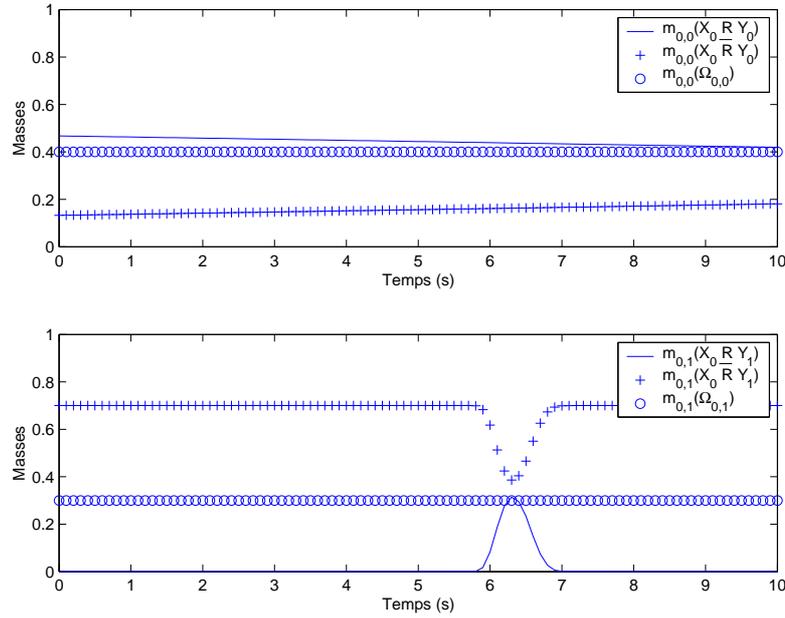


FIG. 3.9 – Evolution de la masse de relation entre X_0 et Y_0 , X_0 et Y_1 .

La figure Fig. 3.10 montre l'évolution de l'association en utilisant les formules de M. Rombaut. Normalement, nous devrions décider que X_0 est en relation avec Y_0 . Pourtant, dès le début de la simulation, la décision de l'association est discutable. En effet, la masse de relation $m_{0,0}(X_0 R Y_0)$ n'est que très légèrement supérieure à $m_{0,0}(\Omega_{0,0})$ lorsque $t < 5.8s$ et devient légèrement inférieure si $t > 5.8s$.

Maintenant, si nous regardons l'évolution des masses avec notre formulation (Fig. 3.11), on peut voir que la décision n'est pas ambiguë : X_0 est en relation avec Y_0 , et cette décision n'est pas remise en cause même lorsque les objets se rapprochent fortement.

Maintenant que nous avons montré le comportement des deux algorithmes d'association pour des valeurs de α fixes, la section suivante décrit le comportement des deux formulations lorsque l'on fait varier α .

Evolution de la masse en fonction de la fiabilité des données

Pour ce test, nous avons pris deux objets évoluant côte à côte, à la même vitesse, distants de $1m$ l'un de l'autre. Ces deux objets s'éloignent progressivement du capteur (de $20m$ à $100m$ avec une vitesse constante de $5m.s^{-1}$). Cet éloignement provoque une chute du coefficient de fiabilité (de 0.9 à $20m$ pour atteindre 0.3 à $100m$). La figure Fig. 3.12

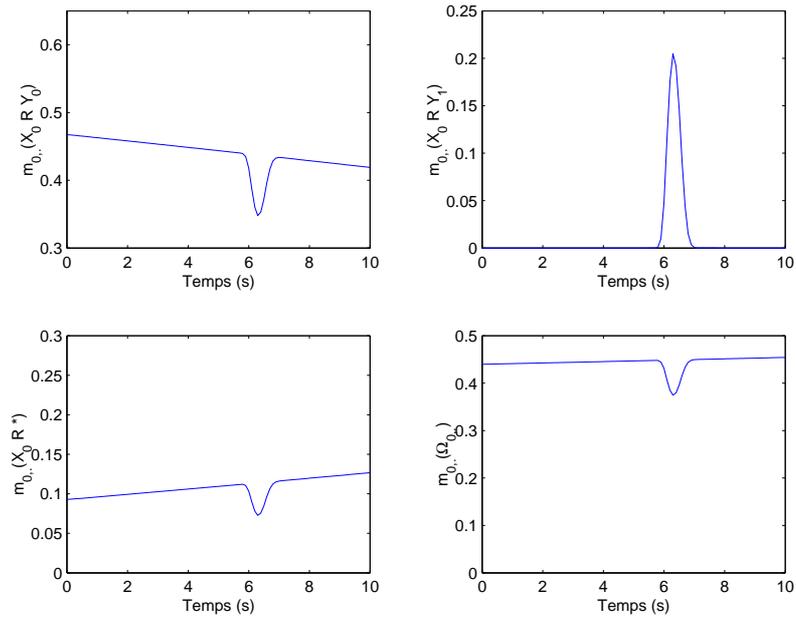


FIG. 3.10 – Association en utilisant les formules de M. Rombaut.

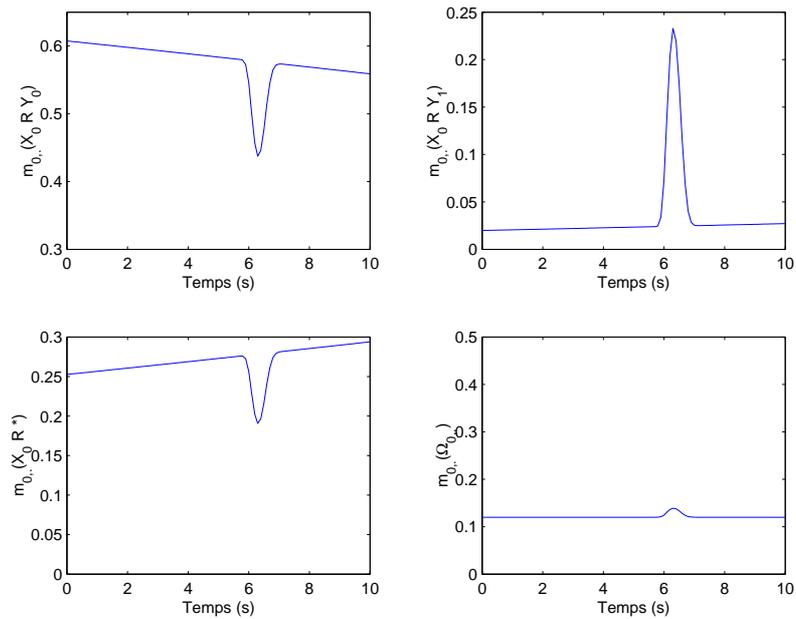


FIG. 3.11 – Association en utilisant les formules modifiées.

montre l'évolution de la fiabilité de la décision en fonction de la fiabilité des données, pour l'algorithme de M. Rombaut et celui que nous proposons. Nous considérons que la décision n'est plus tout à fait fiable si la variation de masse entre la bonne hypothèse et une autre est inférieure à un seuil que nous avons fixé à 0.1.

Lorsque la fiabilité est supérieure à 0.69, les deux algorithmes offrent les mêmes résultats. Cependant, notre algorithme permet de conserver une décision fiable jusqu'à ce que la fiabilité des données atteigne 0.49. Pour l'algorithme de M. Rombaut, la décision n'est

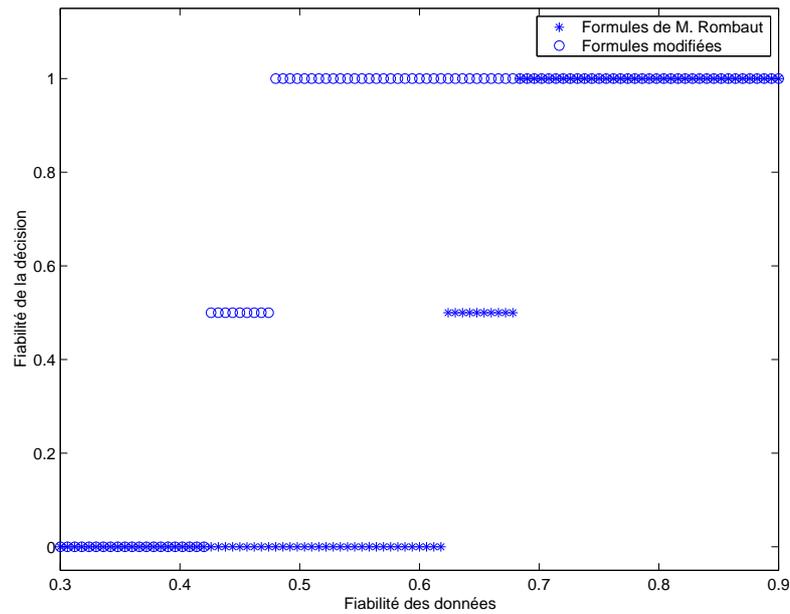


FIG. 3.12 – Evolution de la fiabilité de la décision en fonction de la fiabilité des mesures.

plus fiable en dessous de 0.69 et est erronée si la fiabilité des mesures chute en dessous de 0.63.

Nous avons essayé avec plusieurs valeurs de seuil et nous en arrivons toujours à la même conclusion : notre algorithme reste meilleur lorsque la fiabilité des mesures décroît.

Lorsque des données réelles, issues d'une expérimentation, seront disponible, il pourrait être intéressant de tracer le pourcentage de bonne décision des deux algorithmes avec différentes valeurs de fiabilité selon plusieurs scénarii.

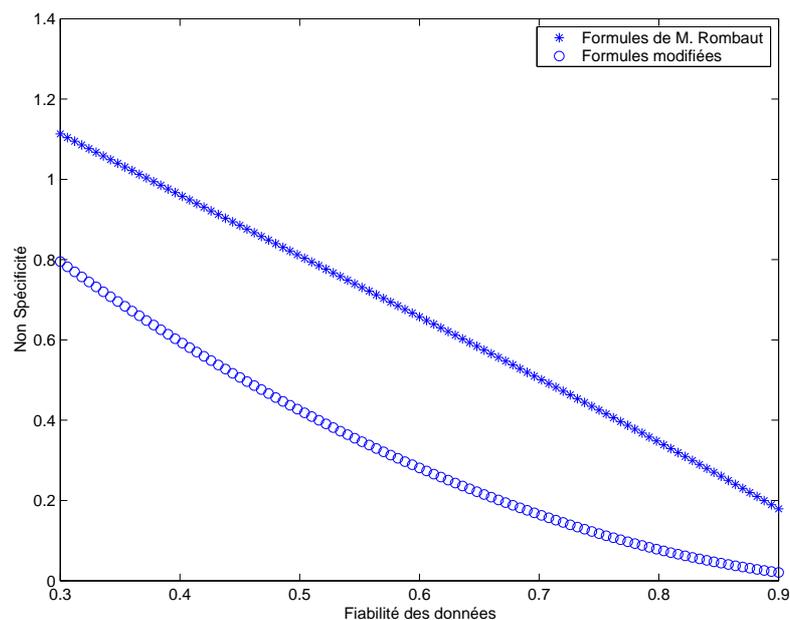


FIG. 3.13 – Evolution de la Non Spécificité en fonction de la fiabilité des mesures.

La figure Fig. 3.13 montre l'évolution de la Non Spécificité des deux algorithmes en fonction de la fiabilité des données. Comme on peut le constater, nos formules permettent d'obtenir un jeu de masses plus spécifique, donc présentant moins d'ambiguïté sur la bonne décision à prendre.

Par ailleurs, nous avons testé les deux algorithmes en faisant varier le nombre d'objets. La figure Fig. 3.14 montre l'évolution de la masse pour l'objet 0 : $m_{0,\cdot}(X_0RY_0)$, $m_{0,\cdot}(X_0R^*)$ et $m_{0,\cdot}(\Omega_{0,\cdot})$.

Pour ce test, nous avons pris les jeux de masses suivants :

$$\begin{aligned} m_{0,0}(X_0RY_0) &= 0.55 & m_{0,j}(X_0RY_j)_{j \neq 0} &= 0.1 \\ m_{0,0}(\overline{X_0RY_0}) &= 0.1 & m_{0,j}(\overline{X_0RY_j})_{j \neq 0} &= 0.55 \\ m_{0,0}(\Omega_{0,0}) &= 0.35 & m_{0,j}(\Omega_{0,j}) &= 0.35 \end{aligned}$$

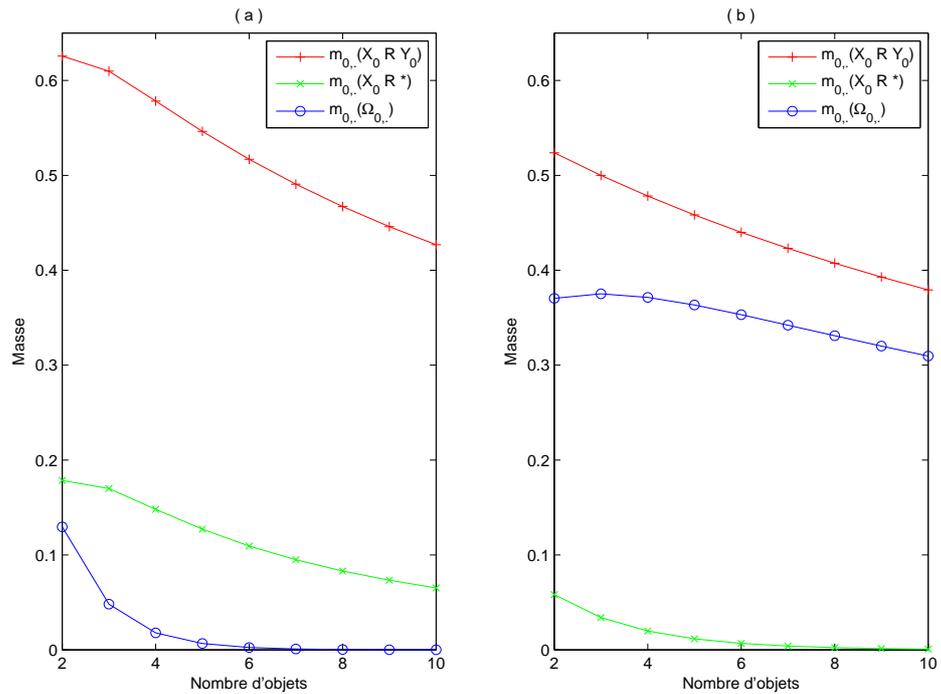


FIG. 3.14 – Variation de la masse pour l'objet 0 en fonction du nombre d'objets présents dans la scène. La masse obtenue avec notre algorithme est tracée en (a) et celle obtenue avec l'algorithme de M. Rombaut est tracée en (b).

On peut constater que notre algorithme donne de meilleurs résultats et l'écart entre les autres masses reste important même lorsque le nombre d'objets augmente. A l'inverse, pour l'algorithme de M. Rombaut, lorsque le nombre d'objets augmente, la masse de

relation $m_{0,}(X_0RY_0)$ tend à se rapprocher de la masse sur l'ensemble $m_{0,}(\Omega_{0,})$. L'écart de masse entre les deux plus proches hypothèses est seulement de 0.07 pour 10 objets avec l'algorithme de M. Rombaut contre 0.35 pour notre formulation.

De plus, avec seulement 2 objets, nous obtenons, avec notre algorithme, une masse de relation supérieure de 0.1 à celle obtenue avec l'algorithme de M. Rombaut qui, par ailleurs, est à peine supérieure à 0.5. On peut aussi remarquer qu'avec la nouvelle formulation, la masse sur le cadre de discernement $\Omega_{i,}$ tombe très rapidement à une valeur proche de 0.

La première partie de l'algorithme de suivi a donc pour fonction de détecter et d'associer les objets les uns aux autres de façon à déterminer les apparitions ou les disparitions de ces mêmes objets. La seconde partie concerne l'utilisation des informations issues de la prédiction des trajectoires des objets.

3.3 Prédiction

Dans l'algorithme complet (Fig. 3.1) que nous proposons, il y a deux prédictions basées sur des pas de temps différents. Tout d'abord, nous avons pu constater qu'en augmentant le nombre de jeux de masse à fusionner, la masse de relation tendait vers 1. Nous avons donc décidé de prédire la trajectoire (distance, angle) des véhicules à $t + dt$ afin de pouvoir créer deux nouveaux jeux de masse. Cette information sera utilisée dans l'étape de fusion, juste avant l'association, comme si elle provenait d'un capteur supplémentaire.

Ensuite, pour améliorer la sécurité des passagers, nous calculons une autre prédiction à $t + n$ secondes, où n dépend de la vitesse du véhicule. Cette prédiction peut alors servir à prévenir le conducteur, suffisamment à l'avance, d'une situation dangereuse.

Nous présentons dans cette partie, les modèles discrétisés qui seront utilisés pour le filtre de Kalman Linéaire et le filtre de Kalman étendu.

3.3.1 Kalman linéaire

Pour ce filtre, nous utilisons le modèle d'évolution des véhicules le plus couramment employé, qui est défini par la relation entre la position, la vitesse, et l'accélération. Par ailleurs, nous avons étendu ce modèle sur deux axes x et y . Il y a donc trois composantes

pour x (x, v_x, γ_x) et trois pour y (y, v_y, γ_y) :

$$x(t) = \frac{1}{2} \cdot \gamma_x \cdot t^2 + v_{x,0} \cdot t + x_0 \quad (3.9)$$

$$y(t) = \frac{1}{2} \cdot \gamma_y \cdot t^2 + v_{y,0} \cdot t + y_0 \quad (3.10)$$

A partir de ces équations, nous obtenons les vitesses et les accélérations en dérivant par rapport à t ⁽³⁾ :

$$\dot{x}(t) = \ddot{x} \cdot t + \dot{x}_0 \quad (3.11)$$

$$\dot{y}(t) = \ddot{y} \cdot t + \dot{y}_0 \quad (3.12)$$

Ces équations (Eq. 3.11 et Eq. 3.12) permettent d'obtenir la position (x, y) pour un instant t ($t > 0$) à partir d'une condition initiale. Il faut alors légèrement transformer ces équations afin d'obtenir $x(t+1)$ à partir de $x(t)$ (idem pour y). On calcule alors l'écart de t à $t+1$ avec le pas de temps Δt variable, ce qui permet d'aboutir aux matrices utilisées dans le filtre :

$$X_{t+1} = \begin{bmatrix} x_{t+1} \\ \dot{x}_{t+1} \\ \ddot{x}_{t+1} \\ y_{t+1} \\ \dot{y}_{t+1} \\ \ddot{y}_{t+1} \end{bmatrix} = \begin{bmatrix} 1 & \Delta t & \frac{\Delta t^2}{2} & 0 & 0 & 0 \\ 0 & 1 & \Delta t & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & \Delta t & \frac{\Delta t^2}{2} \\ 0 & 0 & 0 & 0 & 1 & \Delta t \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \cdot \begin{bmatrix} x_t \\ \dot{x}_t \\ \ddot{x}_t \\ y_t \\ \dot{y}_t \\ \ddot{y}_t \end{bmatrix} \quad (3.13)$$

L'équation de mesures s'écrit comme suit :

$$z_t = \begin{bmatrix} x_t \\ y_t \end{bmatrix} = H \cdot X_t + b_c \quad (3.14)$$

Nous avons donc choisi la matrice H de la façon suivante :

$$H = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix}$$

³en dérivant par rapport à t , on notera par la suite $v_x = \dot{x}$ et $\gamma_x = \ddot{x}$ (idem pour y)

Dans le cas linéaire, les matrices de covariances des bruits de modèle (Q) et de mesure (R) s'écrivent de la façon suivante :

$$Q = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & Q_x & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & Q_y \end{bmatrix} \quad R = \begin{bmatrix} R_x & 0 \\ 0 & R_y \end{bmatrix}$$

Pour simplifier les notations, par la suite, nous ne donnerons que les valeurs de Q_x , Q_y , R_x et R_y .

Les mesures issues du capteur étant en coordonnées polaires (ρ, Θ) , il faut donc convertir ces données en coordonnées cartésiennes avant de calculer l'état prédit :

$$x = \rho \cdot \cos(\Theta)$$

$$y = \rho \cdot \sin(\Theta)$$

puis transformer les coordonnées cartésiennes de la prédiction en coordonnées polaires :

$$\rho = \sqrt{x^2 + y^2}$$

$$\Theta = \arctg\left(\frac{y}{x}\right)$$

Le calcul de (Θ) ci-dessus est généralisé, puisque si les valeurs de x et de y sont positives ou négatives, il faudra ajouter ou retrancher $\frac{\pi}{2}$ autant de fois que nécessaire pour obtenir le bon angle.

Ce type de filtre considère donc que x et y varient de façon linéaire et indépendante. Cependant, ces conditions ne sont pas applicables dans le cas de l'évolution d'un véhicule. C'est pourquoi, il est préférable d'utiliser une modélisation non linéaire.

3.3.2 Filtre de Kalman Etendu

Le Filtre de Kalman Etendu (EKF : Extended Kalman Filter), permet de gérer des modèles non linéaires. Pour ce filtre, nous avons utilisé le modèle d'état décrit dans [65] et qui est défini comme suit :

$$X = \begin{bmatrix} \rho_{t+1} \\ \dot{\rho}_{t+1} \\ \Theta_{t+1} \\ \dot{\theta}_{t+1} \end{bmatrix} = \begin{bmatrix} 1 & \frac{\sin(\omega \cdot \Delta t)}{\omega} & 0 & -\frac{(1-\cos(\omega \cdot \Delta t))}{\omega} \\ 0 & \cos(\omega \cdot \Delta t) & 0 & -\sin(\omega \cdot \Delta t) \\ 0 & \frac{(1-\cos(\omega \cdot \Delta t))}{\omega} & 0 & \frac{\sin(\omega \cdot \Delta t)}{\omega} \\ 0 & \sin(\omega \cdot \Delta t) & 0 & \cos(\omega \cdot \Delta t) \end{bmatrix} \cdot \begin{bmatrix} \rho_t \\ \dot{\rho}_t \\ \Theta_t \\ \dot{\theta}_t \end{bmatrix} \quad (3.15)$$

ω correspond à la vitesse angulaire maximale que peut atteindre l'objet durant l'écart de temps Δt . Dans notre cas, ω est constant au cours du temps, il faut donc lui attribuer une valeur. Cette valeur sera déterminée par expériences dans le chapitre suivant.

Pour la matrice de mesure H , nous utilisons la matrice suivante :

$$H = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{bmatrix}$$

Les matrices de covariances des bruits de modèle (Q) et de mesure (R) s'écrivent de la façon suivante pour le filtre de Kalman étendu :

$$Q = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & Q_d & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & Q_a \end{bmatrix} \quad R = \begin{bmatrix} R_d & 0 \\ 0 & R_a \end{bmatrix}$$

Comme pour le filtre linéaire, par la suite, nous ne donnerons que les valeurs de Q_d , Q_a , R_d et R_a .

Cette fois-ci, le filtre est applicable en utilisant directement les mesures issues du capteur, ce qui permet d'éviter les erreurs de conversion entre les coordonnées cartésiennes et polaires dans le cas du filtre linéaire.

3.4 Conclusion

Dans ce chapitre, nous avons décrit le fonctionnement complet de l'algorithme pour le suivi multi-objets, depuis la création des masses à partir des informations capteurs, jusqu'à la prédiction des trajectoires des véhicules. Nous avons présenté un algorithme d'association qui avait été mis au point par M. Rombaut et auquel nous avons trouvé

certains défauts, le principal étant de ne pas travailler sur le même cadre de discernement entre le moment de la création des masses et l'association des objets. Ce choix peut entraîner par la suite des erreurs de décision par l'ajout d'une masse de croyance trop importante sur l'ignorance. Nous avons donc proposé une nouvelle formulation de l'association permettant de corriger ces défauts. Nous avons alors comparé les résultats obtenus par ces deux algorithmes sur des jeux de données fictives, avec une forte puis une faible fiabilité, mettant en scène 2 objets se rapprochant fortement l'un de l'autre, puis s'éloignant. A partir de ces résultats, nous pouvons, pour l'instant, en déduire que la nouvelle formulation de l'association permet d'obtenir de meilleurs résultats. Cet algorithme d'association est de plus capable de continuer à fonctionner correctement avec une fiabilité des données beaucoup plus faible que ne peut le faire la formulation de M. Rombaut dans le cadre de notre application.

Pour améliorer le suivi multi-objets, nous avons proposé une étape de prédiction de la trajectoire des véhicules. Une première prédiction à $t + dt$ permettra de créer deux nouveaux jeux de masse (l'un à partir de la distance et l'autre à partir de l'angle) qui sera ré-utilisé lors de la fusion avant l'étape d'association. Une seconde prédiction à $t + n$ secondes pourra permettre d'alerter le conducteur d'une situation dangereuse. Nous avons présenté 2 modèles, un modèle linéaire pour le Kalman classique et un modèle non linéaire pour l'EKF.

Le chapitre suivant montre l'utilisation de l'algorithme complet à partir de données synthétiques, puis réelles, en utilisant les formules de M. Rombaut puis les nôtres.

Chapitre 4

Expérimentations

Dans ce chapitre, nous montrons les résultats obtenus par l'algorithme d'association de M. Rombaut et celui que nous proposons en utilisant des données synthétiques puis des données réelles. Nous montrons aussi la prédiction des trajectoires des objets ainsi que l'amélioration qui en résulte pour la fusion.

La première partie de ce chapitre est consacrée à la présentation du simulateur de données que nous avons programmé. En effet, ce simulateur nous a fourni les données synthétiques nécessaires à la mise au point de notre algorithme. Grâce à ces mesures, nous avons pu effectuer une première comparaison entre les deux algorithmes. Puis, toujours avec les données synthétiques, nous montrons les résultats obtenus pour la prédiction de la trajectoire d'un objet, ainsi que l'influence du bouclage de la masse créée à partir de cette prédiction utilisée comme capteur supplémentaire dans l'étape de fusion.

Sachant qu'il n'est pas possible de valider un tel algorithme en partant uniquement de données synthétiques et qu'il n'était toujours pas possible d'avoir des données de nos partenaires dans le cadre du projet RaViOLi, la deuxième partie de ce chapitre présente succinctement un protocole expérimental que nous avons mis en place et grâce auquel nous avons pu obtenir des données réelles. De nouveau, nous comparons les deux algorithmes et nous montrons les résultats de la prédiction ainsi que son utilisation pour le bouclage.

Avant de poursuivre, il convient de préciser que, pour tous les tests qui suivent, nous avons adapté la fonction exponentielle, utilisée pour la création des masses de croyance, afin de mieux séparer les objets.

Pour cela, nous avons ajouté un coefficient de réglage λ comme suit :

$$\begin{aligned} m(X_i R Y_j) &= \alpha_0 \cdot \exp(-\lambda e_{i,j}^2) \\ \overline{m(X_i R Y_j)} &= \alpha_0 \cdot (1 - \exp(-\lambda e_{i,j}^2)) \\ m(\Omega_{i,j}) &= 1 - \alpha_0 \end{aligned} \quad (4.1)$$

Nous avons fixé pour la distance : $\lambda_d = 0.05$ et pour l'angle : $\lambda_a = 30$. En effet, avec ces valeurs et pour $\alpha_0 = 1$, on obtient une masse de croyance en relation inférieure à 0.5 dès lors que l'écart entre deux mesures est supérieur à $2.5m$ pour la distance et $0.15rad$ pour l'angle. Les capteurs n'étant pas parfait, cela permet de compenser les erreurs de mesure surtout pour des objets lointains.

4.1 Données synthétiques : Le simulateur

Dans la plupart des systèmes complexes, il est relativement délicat de mettre en œuvre des approches de surveillance, de diagnostic sans être passé au préalable par une phase de test. Malheureusement, il est souvent impossible de recueillir des données caractérisant l'ensemble des situations possibles ou envisageables permettant de valider le système mis en place. Il est alors nécessaire d'avoir recours à un simulateur. Nous avons donc commencé par tester l'algorithme d'association et de prédiction à l'aide d'un simulateur (Fig. 4.1) que nous avons développé [66].

X1 R Y1 = 0.95 **Fiabilité capteur = 0.79**
X2 R Y2 = 1.0 **Fiabilité capteur = 0.85**



FIG. 4.1 – Affichage de la simulation.

Ce simulateur était la seule source de données que nous avons à notre disposition au début de l'étude. Il permet de créer différents scénarii en jouant sur plusieurs paramètres comme : le nombre de véhicules présents, leur vitesses respectives, le nombre de capteurs, le temps de balayage de chacun des capteurs, la portée en angle et distance des capteurs, ... Le comportement des véhicules est régi par des règles de conduite, ce qui permet de simuler leur déplacement. Le simulateur peut générer des données provenant d'un laser à balayage et d'un radar. On obtient alors une distance et un angle pour chaque

point détecté à chaque pas de balayage. Ensuite, on effectue la fusion entre l'angle et la distance, entre les différents capteurs et on essaie de suivre les véhicules qui ont été détectés dans la scène. On considère que les véhicules sont sur une autoroute et que celui qui est équipé des capteurs circule sur la voie de droite avec une vitesse relative inférieure à celle des autres véhicules. Le simulateur se configure de la façon suivante : on commence par choisir le nombre de véhicules qui interviennent dans le scénario, on leur affecte une vitesse relative par rapport au véhicule de mesure supérieure à $0m.s^{-1}$ et on leur impose une voie de circulation (droite ou gauche). Ensuite, on définit les paramètres des capteurs : position sur le véhicule, résolution en angle et portée minimale et maximale, ainsi que le temps de cycle d'un balayage complet. Les paramètres étant entrés, les déplacements des véhicules sont simulés : leur comportement (doubler ou freiner) dépend de leur distance de sécurité par rapport aux autres. En supposant que les véhicules sont assimilés à de simples points, on calcule la distance et l'angle pour chaque échantillon de temps à partir de la connaissance de leur position. Enfin, on ajoute un bruit blanc gaussien aux mesures avant de commencer l'association (Sec. 3). La simulation s'arrête lorsque tous les véhicules sont sortis du champ de mesure. A ce moment, on affiche une fenêtre montrant l'évolution du scénario avec la variation des masses de croyance pour les objets en relation.

A partir de ce simulateur, nous avons effectué la comparaison entre les deux algorithmes d'association, le test de la prédiction des trajectoires ainsi que le bouclage de la prédiction comme nouvelle mesure au niveau de la fusion. Pour tous ces résultats, le simulateur était paramétré de la façon suivante :

2 capteurs avec un temps de balayage de $50ms$:

- Un laser monté à l'avant gauche du véhicule avec un balayage de 270° par pas de 0.1° et capable de détecter des objets entre 0 et $100m$.
- Un radar centré à l'avant du véhicule balayant sur 180° et permettant de détecter des objets entre 30 et $70m$.

3 véhicules :

- Véhicule 0 : circulant sur la file de droite à une vitesse relative de $5km.h^{-1}$ et autorisé à doubler.
- Véhicule 1 : circulant sur la file de droite avec une vitesse relative de $10km.h^{-1}$, autorisé à doubler mais qui n'apparaît dans la simulation que $2s$ après les deux autres véhicules.
- Véhicule 2 : circulant sur la file de gauche à une vitesse relative de $12km.h^{-1}$ et

interdiction de se rabattre sur la file de droite.

Au cours de la simulation, le coefficient de fiabilité des capteurs, qui est fonction de la distance à laquelle est effectuée la mesure, ne descend pas en dessous de 0.48 pour une mesure à 150m et n'est jamais supérieur à 0.9.

La figure Fig. 4.1 montre ce qu'affiche le simulateur une fois les données entrées et la simulation lancée. Sur cette figure, le scénario fait intervenir 3 véhicules, numérotés 0, 1 et 2. Le véhicule instrumenté est représenté au milieu, sur la file de droite, et ne porte pas de numéro. Les capteurs sont configurés comme dans le paragraphe précédent, ce qui explique que seuls les objets 1 et 2 soient détectés. Le simulateur affiche pour ces deux objets la masse de relation ainsi que la fiabilité des capteurs pour chacun des objets. Les deux objets détectés n'étant pas à la même distance des capteurs, la valeur de fiabilité de ces capteurs est donc différente pour chacun des objets.

4.1.1 Comparaison entre les deux algorithmes

Nous avons tout d'abord testé les deux algorithmes d'association sur les données du simulateur. La figure Fig. 4.2 montre l'évolution de la masse pour le véhicule 1 au cours de la simulation avec l'algorithme de M. Rombaut. La figure Fig. 4.3 montre l'évolution de la masse pour ce même véhicule mais en utilisant les nouvelles formules.

On peut voir sur ces figures que dès le début de la détection, l'approche proposée permet d'obtenir une masse de relation plus élevée (0.7 pour M. Rombaut contre 0.74 pour les nouvelles formules). En fait, tout au long de la simulation, la masse obtenue avec notre algorithme est supérieure ou au moins égale à la masse obtenue avec celui de M. Rombaut.

On remarque aussi qu'il y a une chute de masse vers 45s, cette chute correspond au passage de l'objet à proximité du véhicule instrumenté. Le véhicule étant très près, un faible déplacement de celui-ci entraîne une forte variation de l'angle. Le calcul des masses étant effectué par une fonction exponentielle sur des écarts d'angle d'un instant à l'autre, l'écart augmentant fortement, la masse d'angle chute.

Les tests suivants montrent l'intérêt de l'utilisation d'une prédiction de la trajectoire des objets dans notre algorithme. Le bouclage de cette information au niveau de la fusion comme si il s'agissait d'informations issues d'un capteur supplémentaire permet d'accroître la qualité de la détection et le suivi des objets.

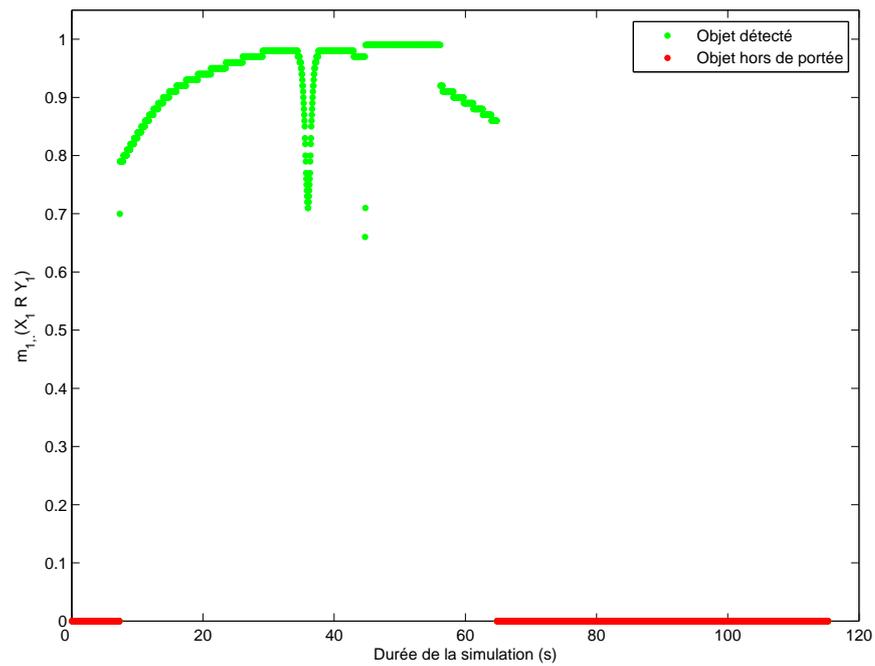


FIG. 4.2 – Evolution de la masse de l’objet 1 ($m_{1,}(X_1RY_1)$) en utilisant les formules de M. Rombaut.

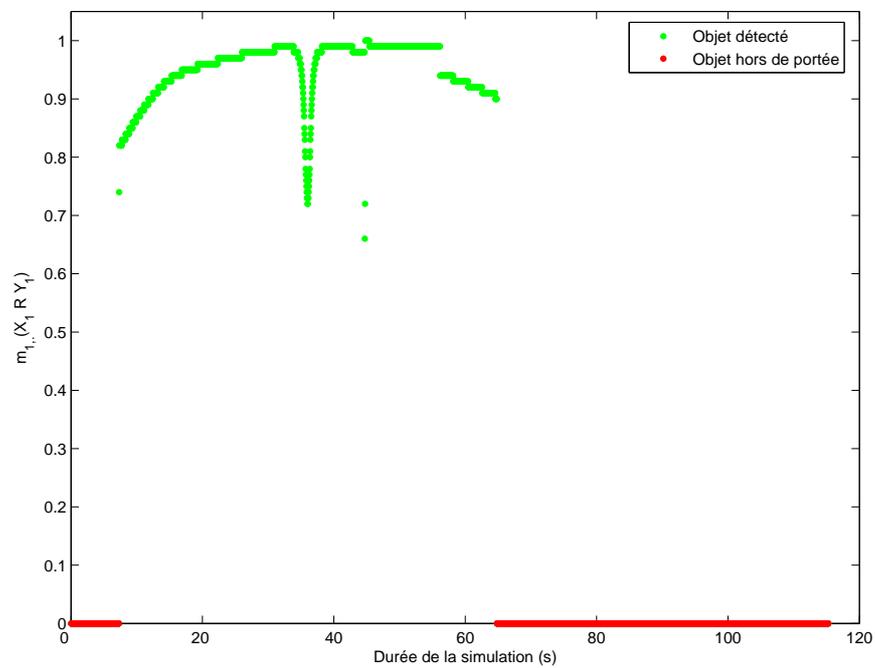


FIG. 4.3 – Evolution de la masse de l’objet 1 ($m_{1,}(X_1RY_1)$) en utilisant les nouvelles formules.

4.1.2 Prédiction des trajectoires

Dans cette partie, nous montrons les résultats obtenus pour la prédiction de la trajectoire des objets. Comme les données sont synthétiques et bruitées avec un bruit blanc Gaussien, nous avons pu utiliser le filtre de Kalman classique. Nous avons pris les équations de mouvement d'un mobile sur un axe comme modèle de la trajectoire des objets. Ce modèle comporte 6 variables (3 composantes sur 2 axes x et y) : la position (x et y), la vitesse (v_x et v_y) et l'accélération (a_x et a_y). La variable x représente la distance du capteur au véhicule en mètres (m), et y représente l'angle capteur-véhicule en radian (rad). Le filtre est réglé avec les paramètres suivants : $Q_x = 0.05$, $Q_y = 0.005$, $R_x = 0.01$ et $R_y = 0.001$ (Sec. 2.2.2). Les bruits de mesure correspondent aux valeurs de bruit que nous avons affectées lors de la création des mesures avec le simulateur. Le bruit affecté sur le modèle est légèrement supérieur de façon à privilégier les mesures qui sont très peu bruitées. Nous avons fait tout d'abord une prédiction à $t + 0.05s$, ce qui correspond au $t + dt$ des capteurs utilisés (Fig. 4.4).

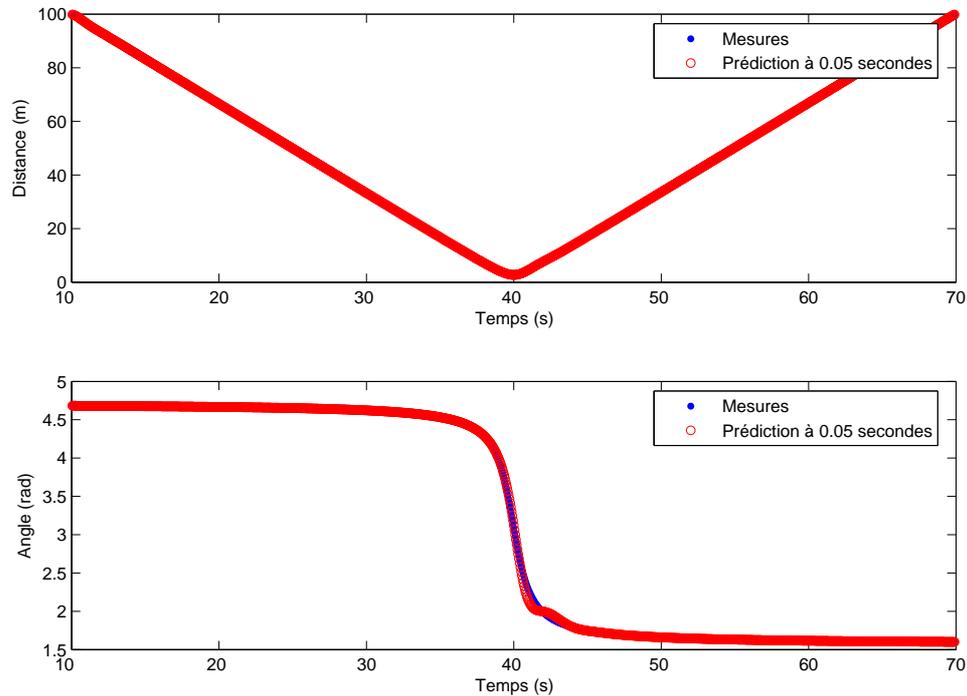


FIG. 4.4 – Prédiction à $t + 0.05s$ de la trajectoire, en position et en angle, pour l'objet 2 avec un filtre de Kalman linéaire.

Les mesures étant simulées et malgré le Bruit Blanc Gaussien, on peut voir que l'évo-

lution de l'objet est la plupart du temps linéaire et donc, ici, le filtre de Kalman linéaire donne de très bons résultats aussi bien pour la distance que pour l'angle.

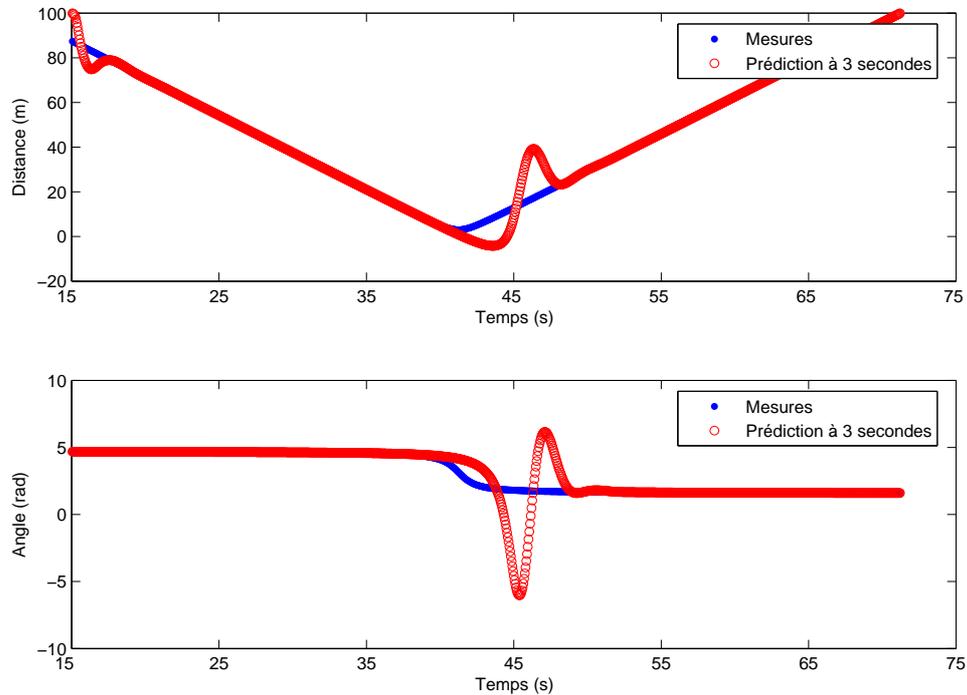


FIG. 4.5 – Prédiction à $t + 3s$ de la trajectoire, en position et en angle, pour l'objet 2 avec un filtre de Kalman linéaire.

Concernant la prédiction à $t + 3s$ (Fig. 4.5), on peut constater que la prédiction est plutôt bonne même si lorsqu'il y a des variations il faut un certains laps de temps pour que le filtre converge de nouveau. En effet, cette prédiction ne doit servir que pour alerter le conducteur en cas de danger et les résultats obtenus sont parfaitement exploitables.

La figure Fig. 4.6 montre la prédiction à $t + 0.05s$ en utilisant le filtre de Kalman non linéaire. Le filtre est réglé avec $Q_d = 1$, $Q_a = 0.1$, $R_d = 0.01$, $R_a = 0.001$ et une vitesse angulaire $w = 0.001rad.s^{-1}$.

On constate que l'on obtient pas de meilleurs résultats qu'avec le filtre linéaire. Cependant, on peut observer (Fig. 4.7) que le filtre non linéaire offre cette fois une prédiction plus juste lorsqu'il s'agit de prédire la trajectoire d'un véhicule 3s à l'avance.

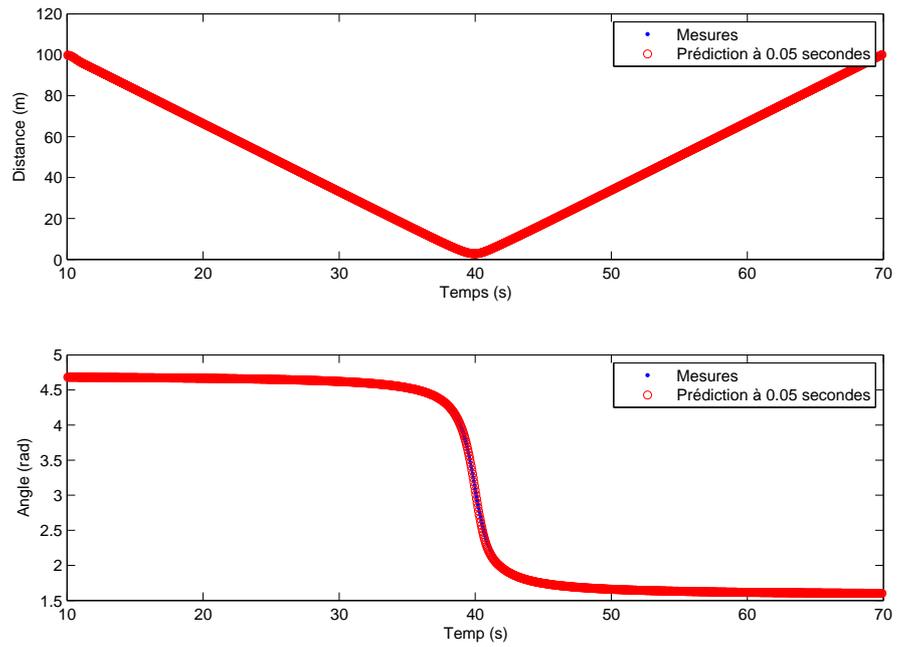


FIG. 4.6 – Prédiction à $t + 0.05s$ de la trajectoire, en position et en angle, pour l'objet 2 avec un filtre de Kalman non linéaire.

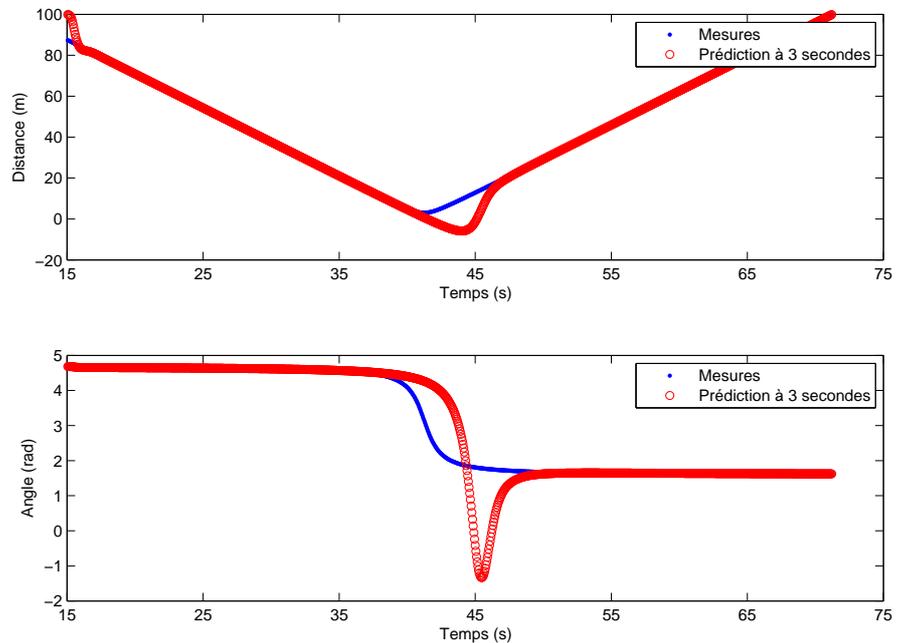


FIG. 4.7 – Prédiction à $t + 3s$ de la trajectoire, en position et en angle, pour l'objet 2 avec un filtre de Kalman non linéaire.

4.1.3 Bouclage de la prédiction

Comme on vient de le montrer la prédiction à $t + 0.05s$ offre de très bons résultats. Nous avons donc voulu tester l'apport de cette information supplémentaire comme si elle provenait d'un nouveau capteur. La figure Fig. 4.8 montre l'évolution de la masse avec et sans bouclage. Comme on peut le constater le bouclage apporte un gain sur la masse de relation non négligeable surtout autour de 40s. A cet instant, le véhicule 2 dépasse le véhicule instrumenté ce qui crée une forte variation d'angle d'une mesure à l'autre et provoque une chute importante de la masse. Le filtrage de Kalman permet de prédire cette variation d'angle rapide, en utilisant le jeu de masse créé à partir de ces informations au moment de la fusion, on en arrive donc à presque annuler cette chute brutale de la masse.

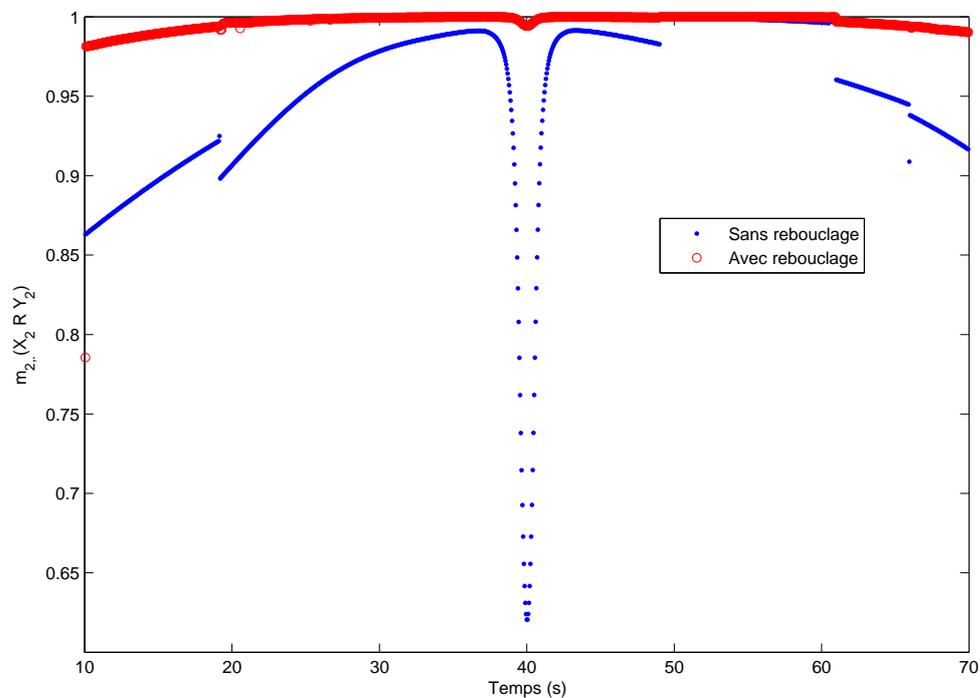


FIG. 4.8 – Evolution de la masse de l'objet 2 ($m_{2,.(X_2 R Y_2)}$) avec bouclage de la valeur de prédiction.

Si la prédiction permet d'augmenter autant la masse de relation, elle peut aussi la faire chuter. L'apport de cette information doit donc se faire en prenant en compte la qualité de la prédiction. La figure Fig. 4.9 montre l'erreur de prédiction sur la distance et sur l'angle. Sur des données synthétiques linéaires, la prédiction par un filtrage de Kalman est plutôt bonne, puisque l'erreur de prédiction est souvent proche de 0, avec un écart de environ

0.4m pour la distance et environ 0.15rad pour l'angle dans la zone où les variations de positions de l'objet suivi sont fortes.

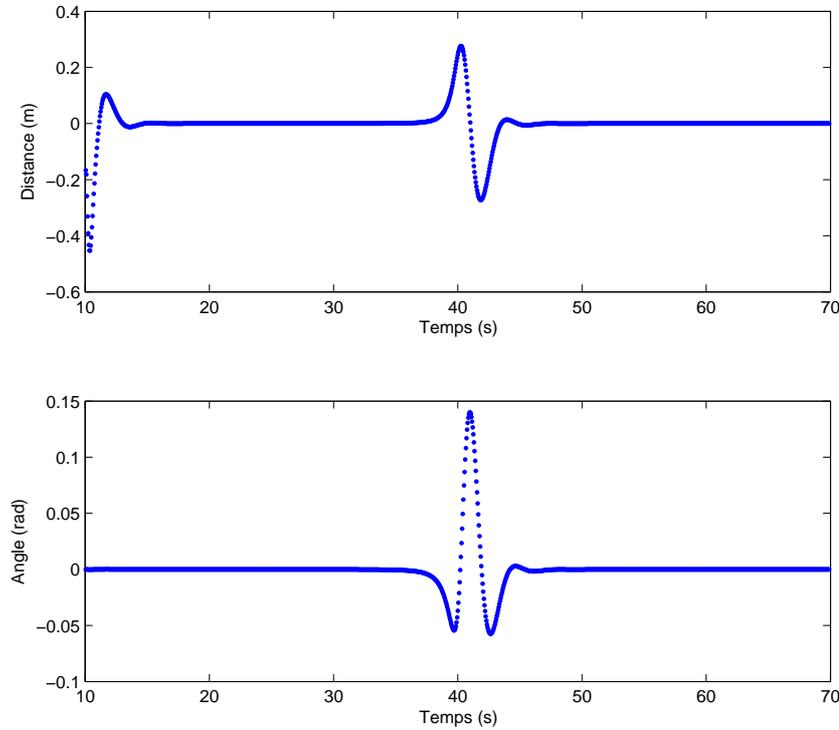


FIG. 4.9 – Erreur de prédiction sur la distance et sur l'angle avec le filtre Non Linéaire pour une prédiction à $t + dt$ seconde.

Les données synthétiques ne correspondent que rarement à ce que l'on trouve dans la réalité, c'est pourquoi, la partie suivante montre les résultats obtenus avec les algorithmes d'association en utilisant des données réelles.

4.2 Données réelles : caméscope numérique

De façon à valider l'algorithme et à tester sa robustesse, nous devons nous procurer des données réelles. Nous n'avons pas pu obtenir de données expérimentales du projet RaViOLi, c'est pourquoi nous avons décidé de mettre en place notre propre protocole expérimental afin de générer nos propres données. Nous avons utilisé, pour cela, un simple caméscope numérique que l'on trouve dans le commerce et nous l'avons placé derrière le parebrise d'un véhicule. Nous avons ensuite filmé une séquence vidéo (Fig 4.10) sur route.

Cette caméra est constituée d'un capteur CCD d'une résolution de 720x576 pixels.



FIG. 4.10 – Image extraite de la séquence filmée.

L'angle de vue est compris entre -0.5 et $+0.5$ radians (environ $\pm 30^\circ$) et les images sont enregistrées à un rythme de 25 images par seconde ($\Delta_t = 0.04s$). La première étape a consisté en un calibrage de la caméra. Nous avons donc filmé, par l'arrière, un véhicule pris comme référence à l'arrêt. Nous avons à notre disposition un télémètre laser de poche, assez précis ($\pm 1cm$ d'erreur à $200m$), qui nous a permis de capturer l'image du véhicule à différentes distances. Compte tenu des moyens techniques dont nous disposions, nous avons effectué des prises de vue du même véhicule placé à une distance de la caméra allant de $1m$ à $60m$ par pas de $10m$. A partir de cette séquence de calibrage, et en supposant que la taille d'un véhicule est fixe et correspond à notre véhicule de référence, nous avons déterminé, par deux méthodes d'interpolations différentes, deux équations qui permettent d'obtenir l'angle et la distance d'un véhicule par rapport à la caméra en fonction de sa hauteur et de sa largeur dans l'image. L'angle est extrait par rapport au centre de gravité du véhicule et la distance, à partir de la largeur et de la hauteur apparente dans l'image. Nous obtenons donc deux sources d'informations⁽¹⁾(Fig. 4.11) fournissant des coordonnées polaires (ρ, Θ) sur chacun des véhicules présents dans la séquence filmée sur route. Le film est affiché image par image à un rythme variable en fonction de la puissance de la machine, et sur chaque image, on effectue le traitement suivant : association des objets avec ceux de l'image précédente, prédiction des trajectoires des véhicules observés et affichage des

¹Comme nous avons utilisé deux méthodes d'interpolation différentes, nous avons fabriqué artificiellement une deuxième source d'information, tout se passe comme si nous disposions de deux capteurs.

données en surimpression sur l'image (éventuellement, bouclage des données prédites).

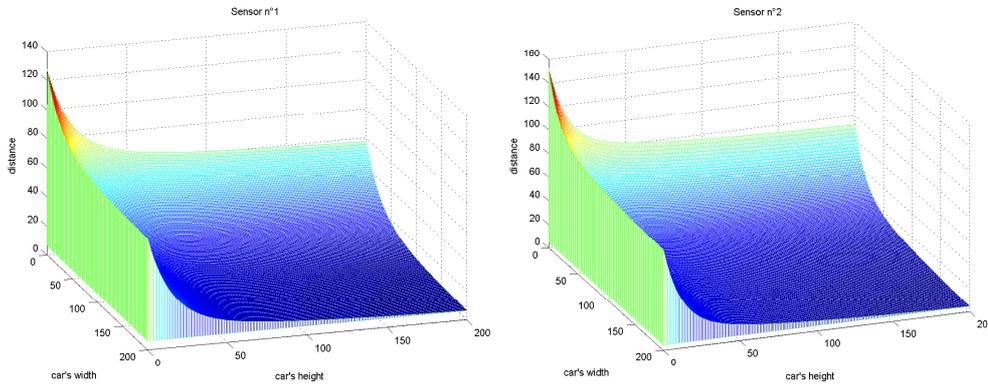


FIG. 4.11 – Caractérisation des deux caméras virtuelles. La distance en m est calculée à partir de la largeur et de la hauteur, en pixels, du véhicule dans l'image.

Les calculs ont été effectués sur un Bi-Xéon $3.6GHz$ sous environnement java, et dans ce cas, on obtient un affichage à environ 22 images par secondes au lieu de 25. En fait, le traitement en lui-même ne prend qu'environ $1ms$ mais l'affichage des images occupe à lui seul environ $45ms$. Dans le cas d'une implémentation de l'algorithme complet dans un véhicule, le traitement en temps réel est tout à fait envisageable. En effet, il ne sera alors pas nécessaire d'afficher les images. De plus, le traitement pourra être implanté dans un calculateur spécialisé ce qui devrait encore améliorer les performances. Dans l'état actuel de développement du logiciel, et compte tenu des performances du matériel sur lequel il est implanté actuellement, nous pouvons traiter 6 objets (association, prédiction), vus par deux capteurs, toutes les $1ms$.

Comme nous ne sommes pas spécialiste du traitement d'image, les mesures que nous avons obtenues par cette méthode peuvent être qualifiées de très bruitées (Fig. 4.12).

En effet, nous pouvons avoir, d'une image à l'autre, une erreur de $20m$ pour un véhicule situé à $70m$ et nous avons pour l'angle, par moment, une erreur de $0.01rad$ pour une mesure de $0.01rad$. D'une façon générale, on constate que la mesure d'angle est plus régulière que celle de la distance. Cela est dû au fait qu'il est difficile d'estimer la profondeur à partir d'une image $2D$, alors qu'il est plus facile d'extraire l'angle surtout que, dans ce cas, nous avons 720 pixels pour une variation de $1rad$ soit une précision théorique de $1.45mrad$ par pixel. En pratique, l'angle étant mesuré à partir de la position du centre

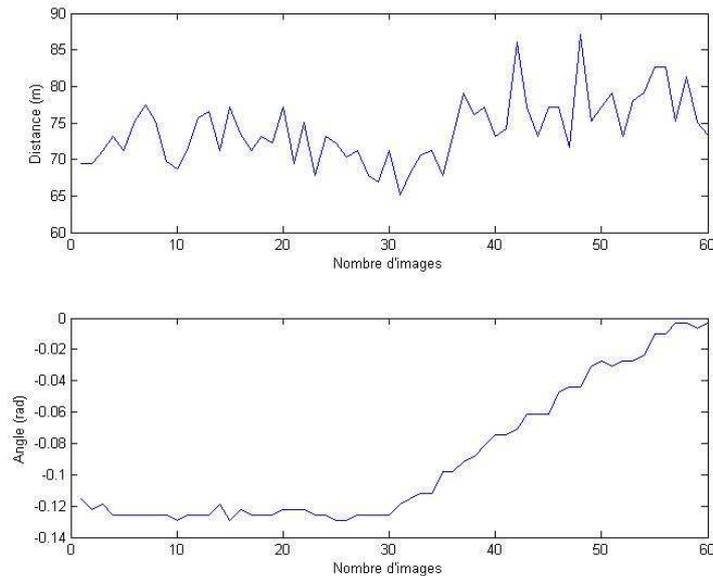


FIG. 4.12 – Evolution de la distance et de l’angle pour un objet détecté.

de gravité du véhicule qui est lui même estimé avec une erreur importante, cette résolution du capteur entraîne des erreurs importantes de l’estimation de ce paramètre. Nous noterons que nous n’avons pas essayé de lisser les mesures car le but recherché ici est de tester la robustesse de notre algorithme.

Association d’objets

La figure Fig. 4.13 montre l’évolution de la masse pour un seul objet perçu et donc pour un seul objet connu.

Cet objet est suivi pendant 300 images (12s) et se situe à environ 20m du capteur. Comme on peut le constater, dans ces conditions, la masse de relation varie de 0.57 à 1 mais elle est plus souvent proche de 1. La chute de masse à 0.57 est due à une erreur de mesure à cet instant qui touche à la fois l’angle et la distance : cette erreur provoque 8.2% d’écart d’angle et 14.6% d’écart de distance entre $t - 1$ et t pour le même objet. Cet écart est suffisant pour faire chuter les deux jeux de masses, créées à partir de la fonction exponentielle. Nous remarquons que l’étape de fusion ne permet pas de compenser ces erreurs.

La séquence que nous avons filmée se compose de 3230 images (soit environ 2min10s) et, tout au long de cette vidéo, nous avons perçu 7063 véhicules, ce qui représente entre 0 et 6 véhicules par image.

La figure Fig. 4.14 montre l’évolution de la masse de croyance sur * pour toute la

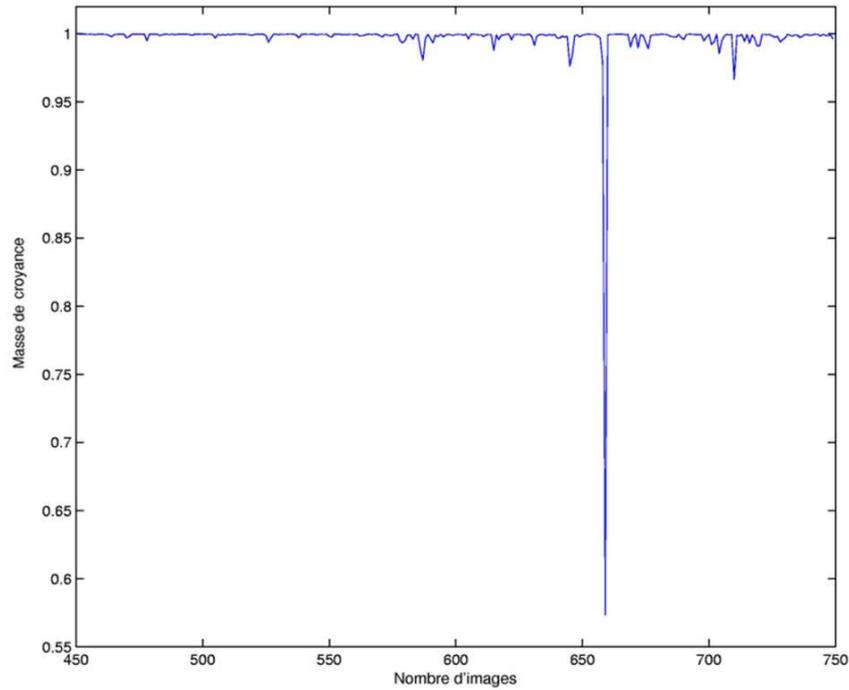


FIG. 4.13 – Evolution de la masse de croyance pour un objet détecté.

séquence en utilisant les deux algorithmes d'association.

Dans notre scénario (Fig. 4.14) on peut voir qu'il y a beaucoup d'apparition et de disparition de véhicules (763 pendant les 3230 images). On peut remarquer que la masse sur * avec les nouvelles formules est égale ou supérieure par rapport à la masse obtenue avec la formulation de M. Rombaut. La masse de relation (Fig. 4.13) est tracée sur une période de 300 images (entre l'image 450 et 750). On peut voir sur la figure Fig. 4.14, que pendant cette période, il n'y avait qu'un seul objet perçu et qu'il est toujours reconnu et suivi.

Association d'objets avec un seul capteur

Pour cette partie, les données ne proviennent que d'un seul capteur et pour un seul objet. Cet objet est suivi pendant 260 images (environ 10s) et se situe à peu près à 70m du capteur. La figure Fig. 4.15 montre l'évolution du coefficient de fiabilité pour les mesures de cet objet.

Nous avons tracé la comparaison entre les deux algorithmes d'association pour les jeux de masses $m_{0,}$ (Fig. 4.16) et $m_{.,0}$ (Fig. 4.17) ainsi que la décision globale prise en accord avec ces deux fonctions (Fig. 4.18). Sur les figures Fig. 4.16 et Fig. 4.17, on peut voir qu'avec notre formulation, nous avons toujours la masse $((X_0RY_0)$ et $(Y_0RX_0))$ ainsi que

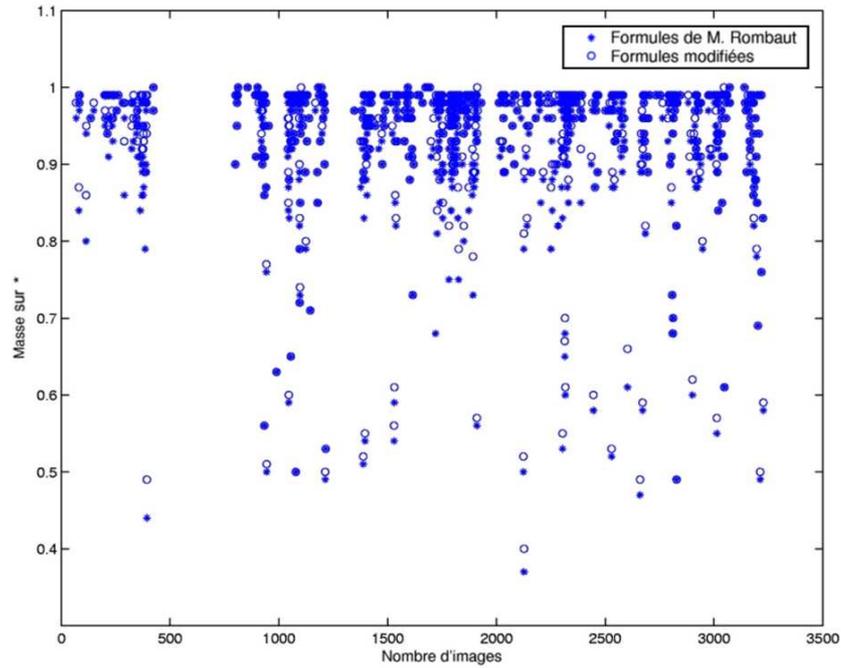


FIG. 4.14 – Evolution de la masse sur * sur la totalité de la séquence.

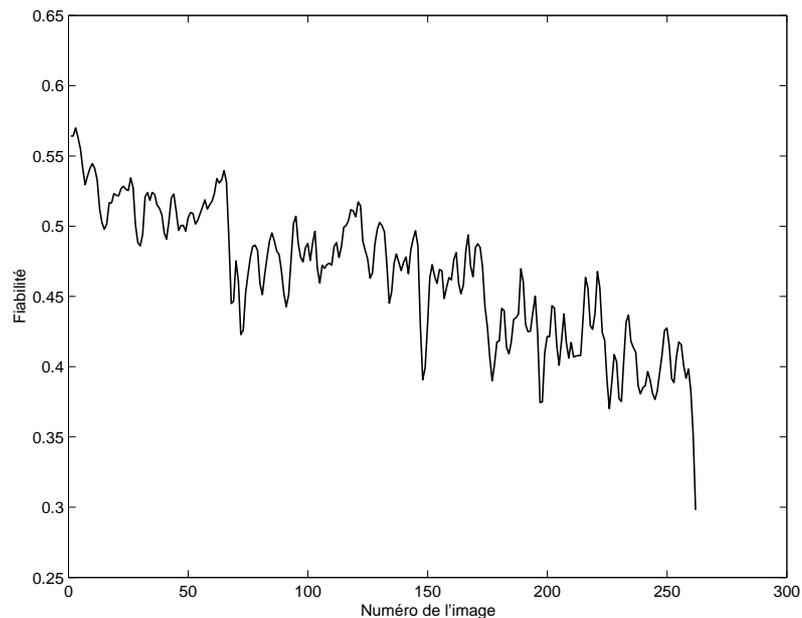


FIG. 4.15 – Evolution de la fiabilité des données.

la masse sur * ((X_0R^*) et (Y_0R^*)) égale ou supérieure à celle obtenue avec les formules de M. Rombaut. Avec notre formulation, la masse sur Ω est toujours inférieure à la masse obtenue avec la formulation de M. Rombaut. De ce fait, nous obtenons des décisions différentes à partir des fonctions $m_{0,\cdot}$ et $m_{\cdot,0}$.

Par conséquent, la décision globale (Fig. 4.18), issue du recoupement entre les deux jeux de masses, est différente pour les deux algorithmes.

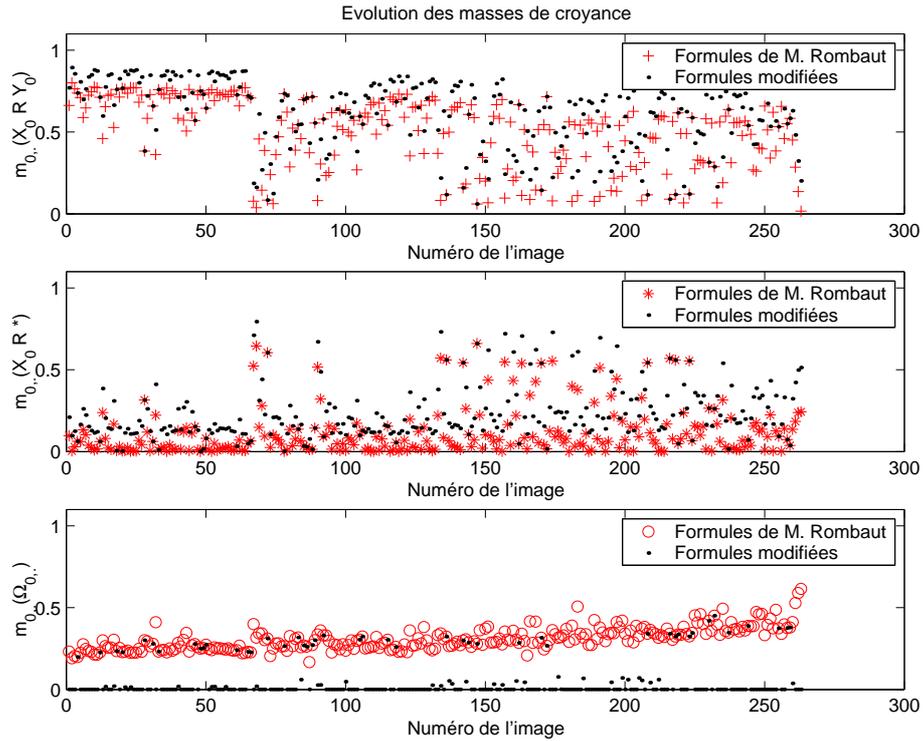


FIG. 4.16 – Evolution de la masse de relation, de * et $Ω$ pour la fonction $m_{0,·}$, avec un objet perçu.

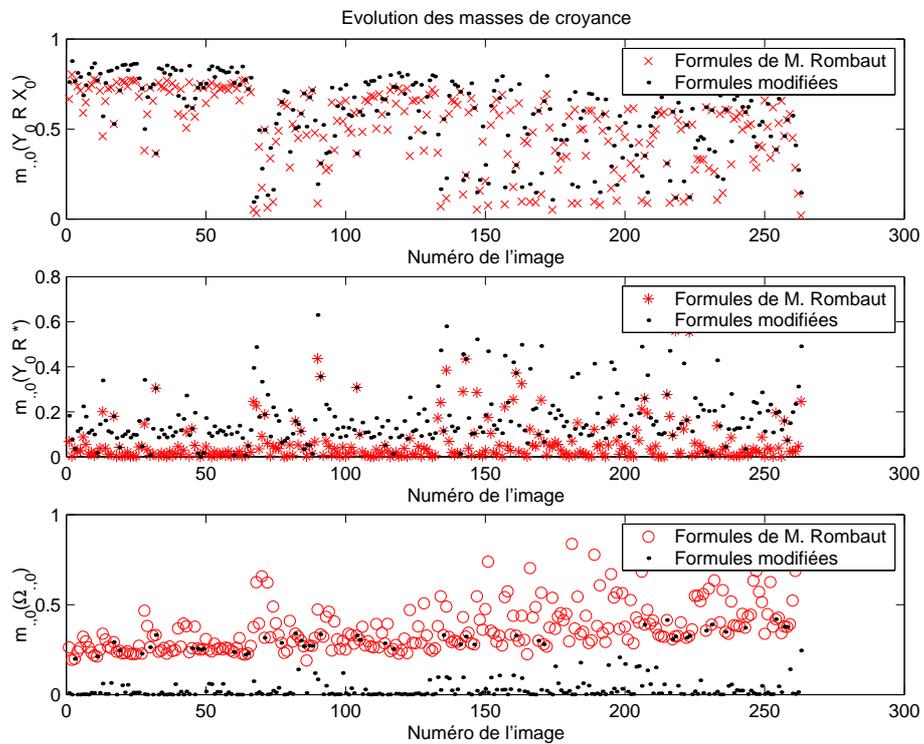


FIG. 4.17 – Evolution de la masse de relation, de * et $Ω$ pour la fonction $m_{·,0}$ avec un objet perçu.

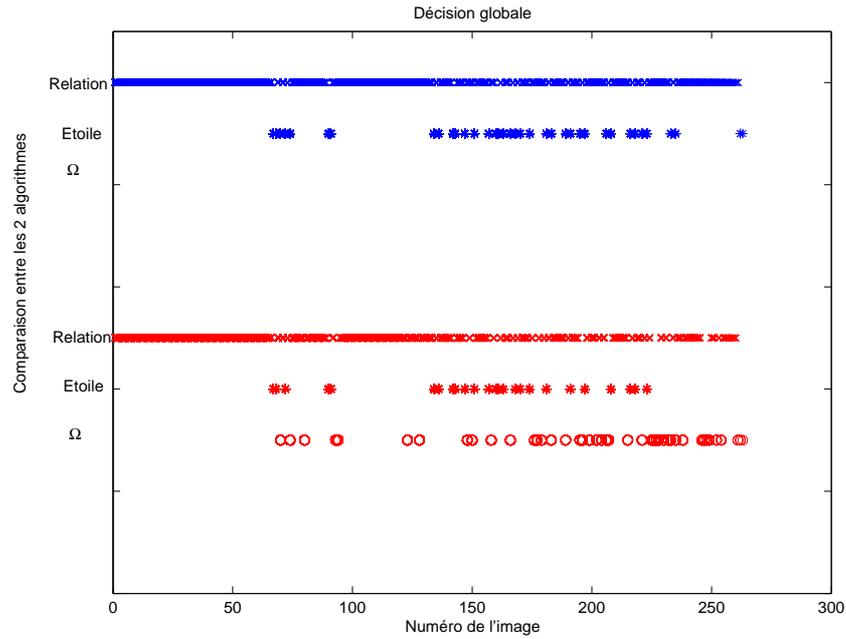


FIG. 4.18 – Comparaison de la décision globale (issue des fonctions $m_{0,.}$ et $m_{.,0}$) pour les deux algorithmes. Le tracé du bas correspond à la décision prise avec l'algorithme de M. Rombaut et celui du haut correspond aux formules modifiées.

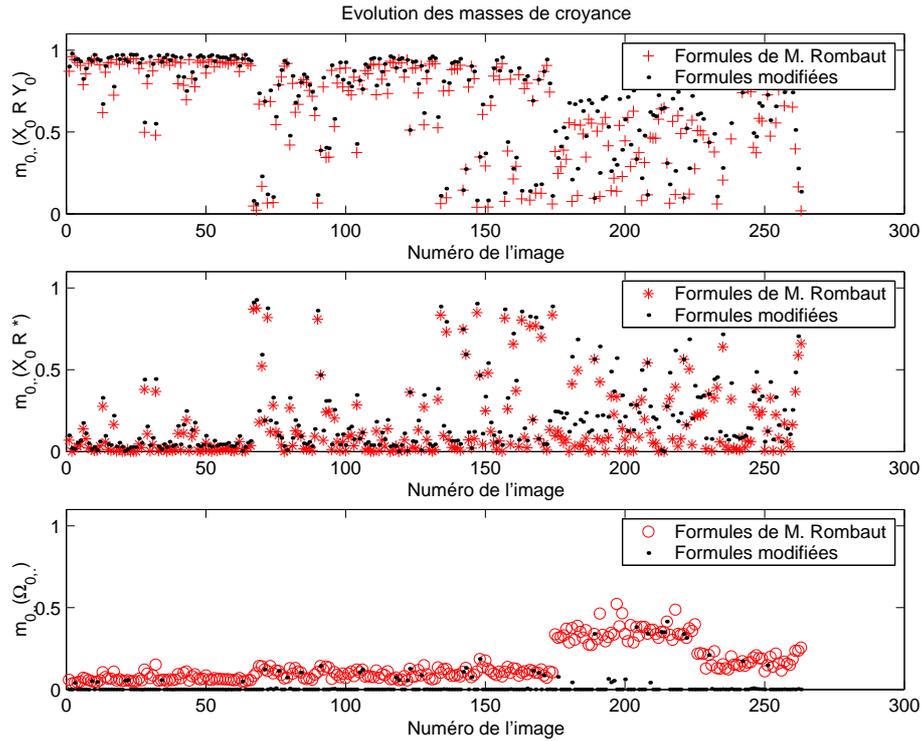
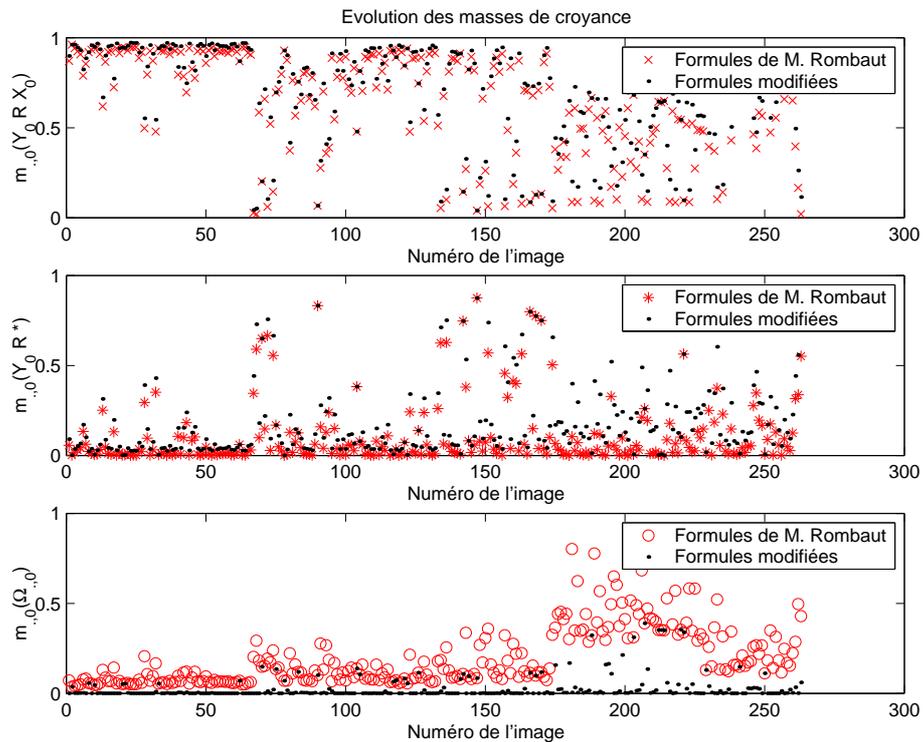
Avec notre algorithme, nous ne décidons jamais Ω , ce qui veut dire que nous avons toujours une décision. A l'inverse, nous avons plus de décisions sur $*$, ce qui n'est pas vraiment un problème, car si on décide que l'objet est un nouvel objet (nous n'avons pas pu le suivre), l'objet est quand même détecté et assimilé à un nouvel objet. Dans le cas où on décide Ω , nous n'avons aucune information sur la nature de l'objet (peut être même qu'il n'existe pas).

Association d'objets avec fusion de deux capteurs

Pour cette expérience, nous avons extrait les mesures sur un objet (le même que dans la partie précédente) à partir de deux sources d'information (Sec. 4.2). Le coefficient de fiabilité ne dépendant que de la distance entre l'objet et le capteur, l'évolution de la fiabilité reste la même que précédemment (Fig. 4.15).

La comparaison entre les deux algorithmes pour les masses de la fonction $m_{0,.}$ est tracée sur la figure Fig. 4.19 et sur la figure Fig. 4.20 pour la fonction $m_{.,0}$. La décision globale issue de ces deux jeux de masses est tracée sur la figure Fig. 4.21.

Sur les figures Fig. 4.19 et Fig. 4.20, on peut voir qu'avec les nouvelles formules, les masses de relation ((X_0RY_0) et (Y_0RX_0)) et les masses sur $*$ ((X_0R*) et (Y_0R*)) sont

FIG. 4.19 – Evolution de la masse de relation, * et Ω pour $m_{0,}$ avec un seul objet perçu.FIG. 4.20 – Evolution de la masse de relation, * et Ω pour $m_{,0}$ avec un seul objet perçu.

toujours égales ou supérieures aux masses obtenues avec l'algorithme de M. Rombaut, mais, grâce à la fusion de données, l'écart de masses entre les deux algorithmes s'affaiblit.

On peut faire le même constat avec la masse de Ω .

On peut remarquer qu'entre les images 175 et 225, un capteur est défaillant, les mesures ne proviennent donc plus que d'un capteur. Durant ces 50 images, on se retrouve dans le cas précédent (Sec. 4.2) et on peut constater que notre algorithme d'association fonctionne toujours très bien.

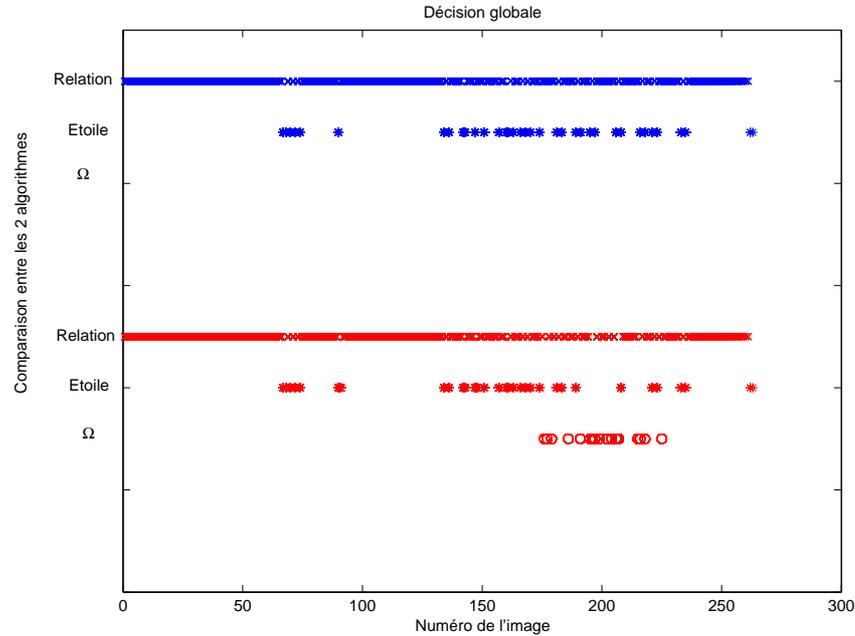


FIG. 4.21 – Comparaison de la décision globale (issue des fonctions $m_{0,\cdot}$ et $m_{\cdot,0}$) pour les deux algorithmes. Le tracé du bas correspond à la décision prise avec l'algorithme de M. Rombaut et celui du haut correspond aux formules modifiées.

On peut vérifier ce bon fonctionnement sur la courbe de décision globale (Fig. 4.21). Les décisions sont identiques lorsque les deux capteurs fonctionnent. Lorsqu'un capteur est défaillant (entre les images 175 et 225), on peut voir que notre algorithme permet toujours d'associer l'objet.

La différence au niveau de la masse allouée à l'ensemble $\Omega_{0,\cdot}$ (où $\Omega_{\cdot,0}$) peut être illustrée de manière différente comme le présente la figure Fig. 4.22 pour la formulation de M. Rombaut et la figure Fig. 4.23 pour notre formulation.

Sur ces figures, nous avons représenté les probabilités pignistiques des 3 classes ((X_0RY_0) , (X_0RY_1) et (X_0R^*)) dans un triangle équilatéral dont chacune des hauteurs représente la probabilité pignistique d'une classe. Sur cette figure est aussi représentée, en traits pleins, la zone de rejet possible pour deux valeurs de coûts ($\lambda_0 = 0.25$ et $\lambda_0 = 0.5$). De la même manière, la prise de décision sans rejet est également représentée en trait pointillé. On peut

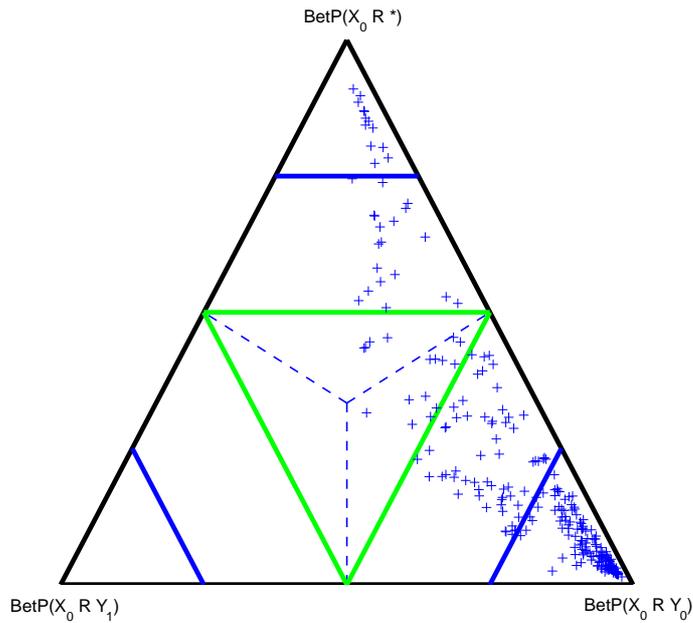


FIG. 4.22 – Répartition des probabilités pignistique en utilisant les formules de M. Rombaut

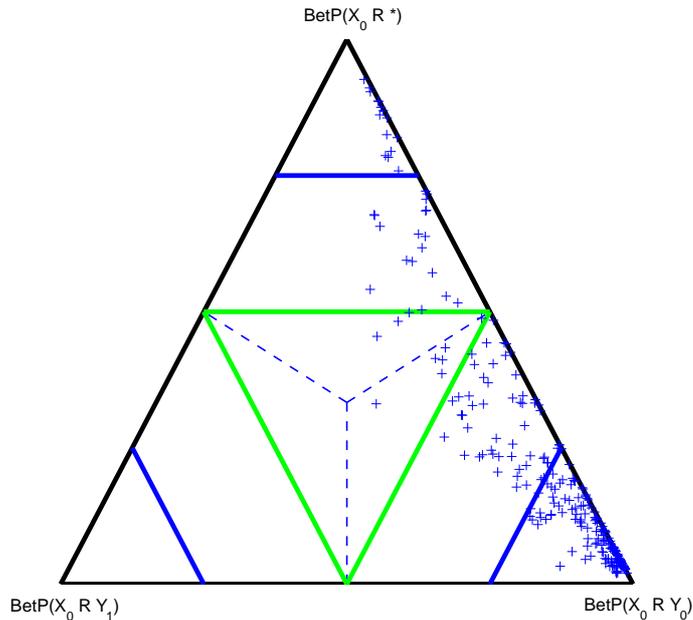


FIG. 4.23 – Répartition des probabilités pignistique en utilisant les nouvelles formules
 constater que les vecteurs placés dans le triangle représentant les probabilités pignistiques obtenues avec l'approche proposée par M. Rombaut ont tendance à être plus proche du centre de gravité que celles obtenues avec notre approche. Ainsi, pour une valeur de coût donné le nombre de rejet est plus important avec la formulation de M. Rombaut. Cette

remarque est confirmée par la figure Fig. 4.24 qui représente le taux de rejet en fonction de la valeur du coût de rejet.

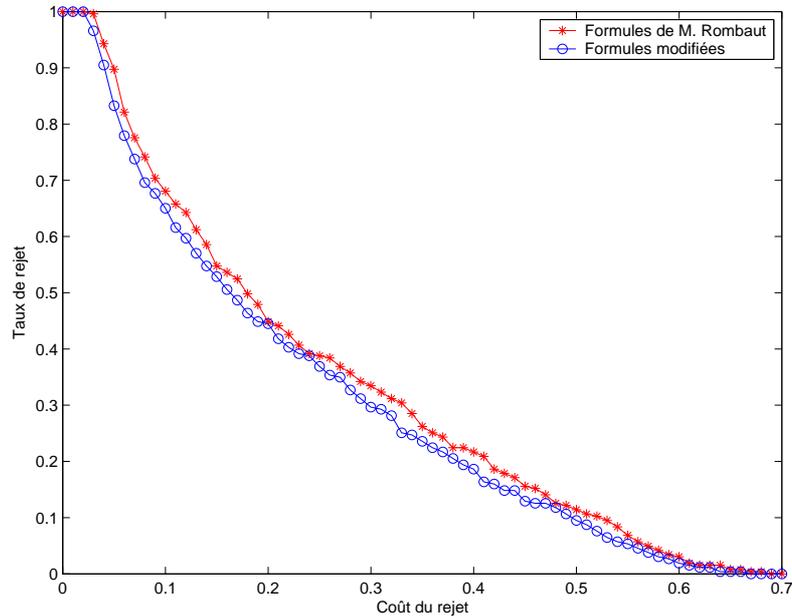


FIG. 4.24 – Taux de rejet en fonction du coût de rejet pour le risque pignistique.

4.2.1 Prédiction des trajectoires

Les données réelles que nous avons extraites de la caméra nous ont permis de tester les algorithmes de filtrages. Pour commencer, nous présentons les résultats de prédiction obtenus à l'aide du filtre de Kalman linéaire.

Filtre de Kalman Linéaire

Les données issues de la caméra sont appliquées en entrée du filtre de Kalman classique. Comme on peut le constater sur la figure Fig. 4.25, le filtre de Kalman linéaire qui n'est normalement pas adapté pour la prédiction des trajectoires non linéaires, permet d'obtenir des résultats satisfaisants. Nous avons comparé la prédiction de la trajectoire en utilisant plusieurs valeurs de Q et R afin de déterminer les paramètres permettant la meilleure prévision, et nous avons conservé $Q_x = 0.1$, $Q_y = 0.01$, $R_x = 0.1$ et $R_y = 0.01$ pour la suite des tests.

Même si ce filtre offre de bons résultats pour une prédiction à $t + 0.04s$, on remarque (Fig. 4.26) qu'il n'est plus capable de prédire dès lors que l'on augmente la durée.

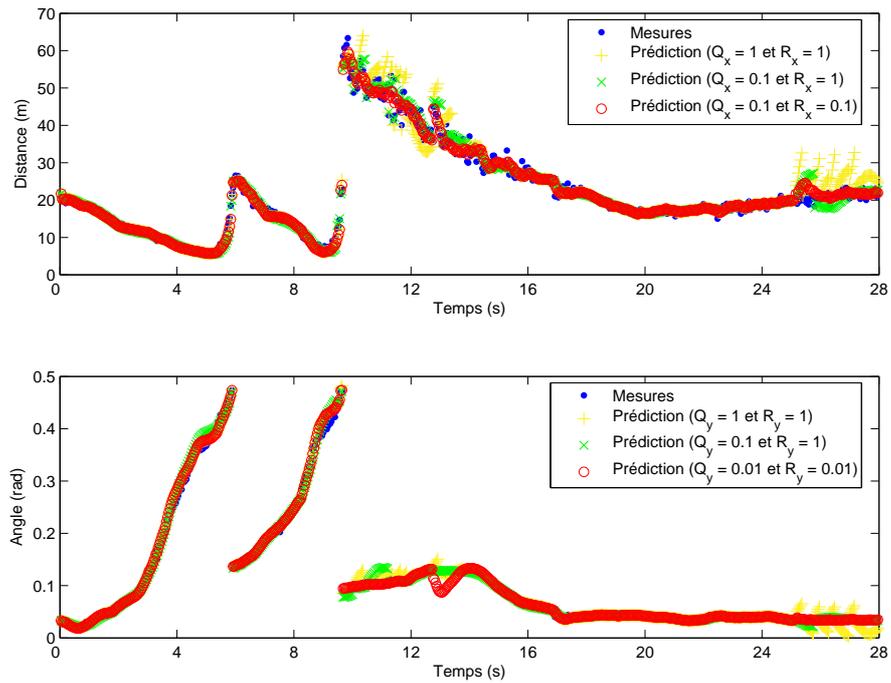


FIG. 4.25 – Prédiction à $t + 0.04s$ de la trajectoire pour l'objet 0 en utilisant le filtre de Kalman Linéaire.

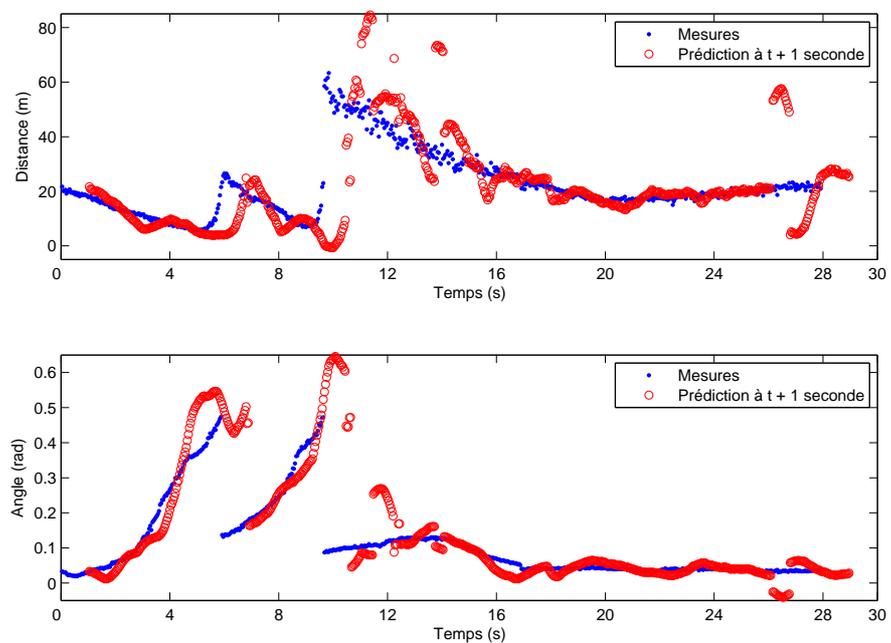


FIG. 4.26 – Prédiction à $t + 1s$ de la trajectoire pour l'objet 0 en utilisant le filtre de Kalman Linéaire.

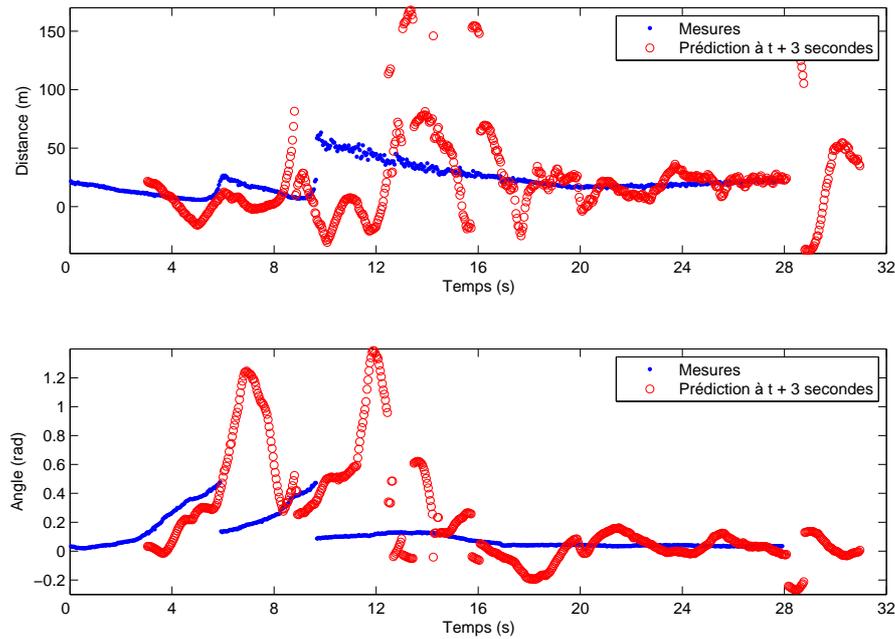


FIG. 4.27 – Prédiction à $t + 3s$ de la trajectoire pour l'objet 0 en utilisant le filtre de Kalman Linéaire.

En effet, à $t + 1s$, seule la prédiction de la distance pourraient éventuellement encore être exploitée du fait de l'erreur de prédiction raisonnable compte tenu de la distance du véhicule. En revanche, l'erreur sur l'angle ne nous permet pas d'utiliser cette information.

Bien que la prédiction à $t + 1s$ soit déjà mauvaise, nous avons tout de même inclus la prédiction à $t + 3s$ (Fig. 4.27) de façon à pouvoir la comparer avec celles issues des autres filtres utilisés dans la partie suivante. Comme on peut le voir, le filtre de Kalman linéaire n'est plus du tout applicable dans cette situation.

Filtre de Kalman Non Linéaire

La figure Fig. 4.28 montre les résultats obtenus pour la prédiction de la distance et de l'angle à $t + 0.04s$ pour l'objet 0 en utilisant le filtre de Kalman Étendu. Le filtre est réglé avec les valeurs suivantes : $Q_d = 0.1$, $Q_a = 0.01$, $R_d = 5$, $R_a = 0.5$ et ω variable.

On remarque que la prédiction de la distance ne semble pas affectée par le choix de ω . A l'inverse, la prédiction de l'angle est modifiée en fonction de la valeur de la vitesse angulaire et on peut remarquer que plus cette vitesse est faible et meilleure est la prédiction. D'après cette série d'expériences, nous avons pu vérifier que les meilleurs résultats étaient obtenus pour $\omega = 0.0005rad.s^{-1}$. Dans ces conditions, le filtre de Kalman

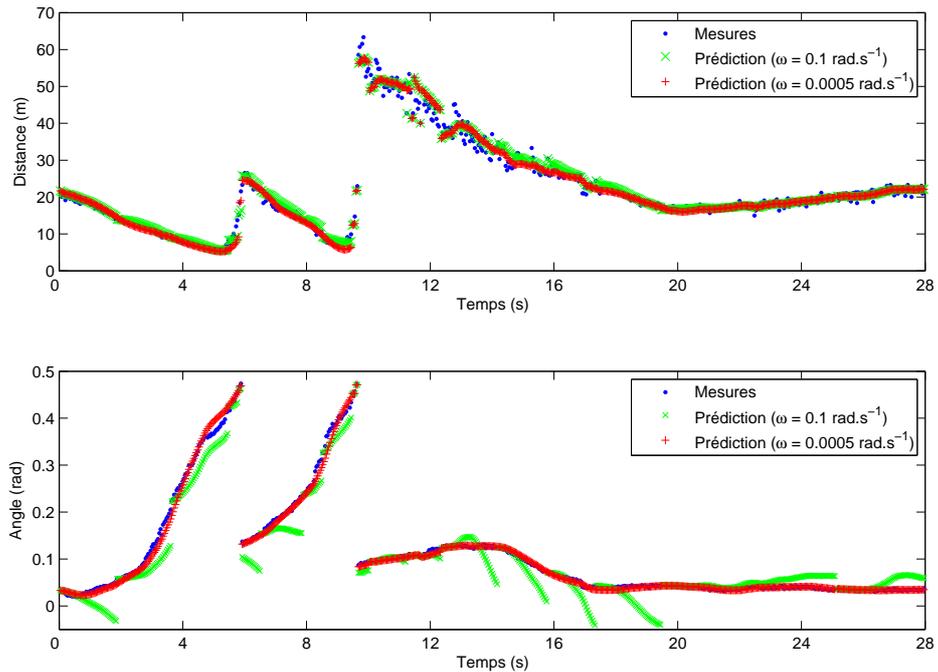


FIG. 4.28 – Prédiction à $t + 0.04s$ de la trajectoire pour l'objet 0 en utilisant l'EKF.

Étendu permet de fournir des résultats similaires au filtre linéaire pour un Δt de $0.04s$.

Les deux changements de distance et d'angle que l'on observe vers 6 et 10 secondes sont dus au fait que l'objet 0 est toujours le véhicule détecté le plus proche. De plus, le véhicule instrumenté roule sur la file de gauche à une vitesse supérieure aux autres, donc chaque fois qu'un véhicule est dépassé, l'étiquette "objet 0" est affectée à un autre véhicule. C'est ce qui explique que la distance chute progressivement puis augmente brutalement⁽²⁾ : l'objet 0 a été dépassé et le premier objet visible a pris sa place.

La prédiction à $t + 3s$ (Fig. 4.29) est, contrairement au filtre linéaire, plutôt exploitable pour la distance et un peu moins pour l'angle. On peut remarquer que le filtre permet d'obtenir une bonne prévision si la trajectoire est stable ($t > 22s$). Cependant, le but de la prévision à $t + 3s$ est d'estimer si le conducteur présente une conduite à risque susceptible de provoquer un accident. Et, dans ce cas, il est impossible d'utiliser ce filtre. Le mouvement étant fortement non linéaire, c'est ce qui explique que le filtre de Kalman étendu ne permet pas une prédiction correcte à $t + 3s$ sauf lorsque la trajectoire est stable.

²L'angle, à l'inverse, ne fait qu'augmenter car le véhicule en cours de dépassement se trouve dans la partie droite de l'image, donc l'angle est positif, et il augmente jusqu'à ce que ce véhicule sorte progressivement du champ de vision de la caméra ($+0.5rad$).

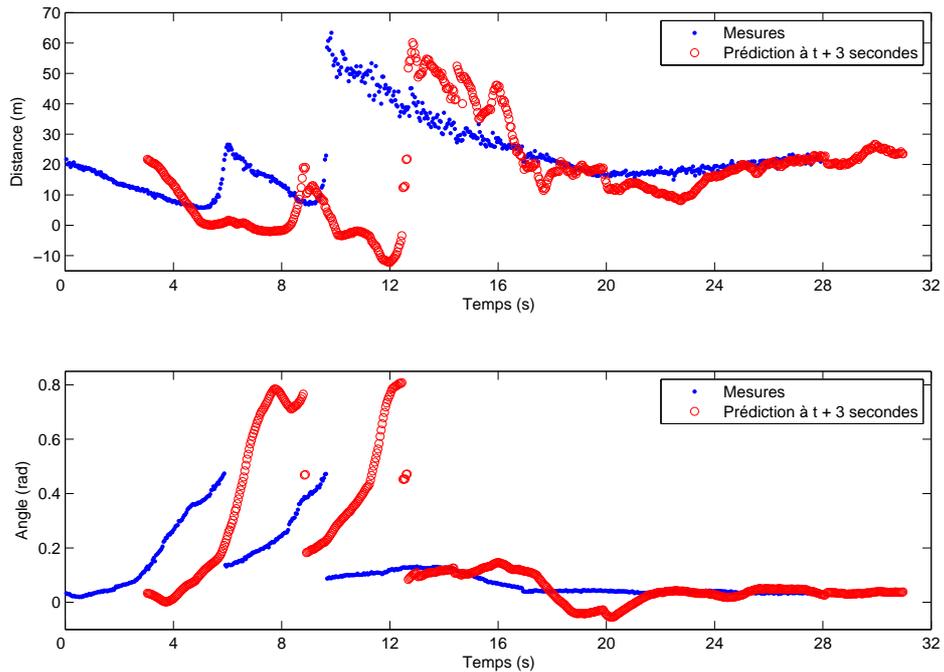


FIG. 4.29 – Prédiction de la distance et de l’angle pour l’objet 0 à $t + 3s$ en utilisant l’EKF.

On pourra alors choisir d’effectuer la prédiction sur un temps plus court, de cette façon, l’erreur de prédiction sera plus faible.

On peut imputer les erreurs de prédiction au fait que les données sont très bruitées mais aussi et surtout au fait que l’on prédit assez loin dans le temps et qu’il n’est pas possible de prévoir le comportement d’un conducteur sur une telle durée. Il est néanmoins possible d’améliorer ces résultats en lissant les données. Cependant, notre but est de fournir un algorithme robuste, c’est pourquoi nous n’avons pas essayé d’améliorer nos données caméra.

De façon à obtenir une prévision plus juste, il pourrait être utile de mettre en place un filtrage particulière [67, 68, 69, 70]. Ce filtre est en effet beaucoup plus robuste que le filtre de Kalman étendu sur des mouvements non linéaires.

4.2.2 Influence du bouclage

Les résultats étant plutôt bon pour $t + \Delta t$, nous avons bouclé la prévision à $t + 0.04s$ comme si il s’agissait de données provenant d’un capteur supplémentaire. Pour les tests suivants, nous avons suivi l’objet 0 pendant quelques secondes. Puis, nous avons

commencé par étudier l'influence du bouclage en utilisant les données d'une seule caméra. Les résultats de l'évolution de la masse de suivi pour cet objet au cours du temps sont tracés sur la figure Fig. 4.30.

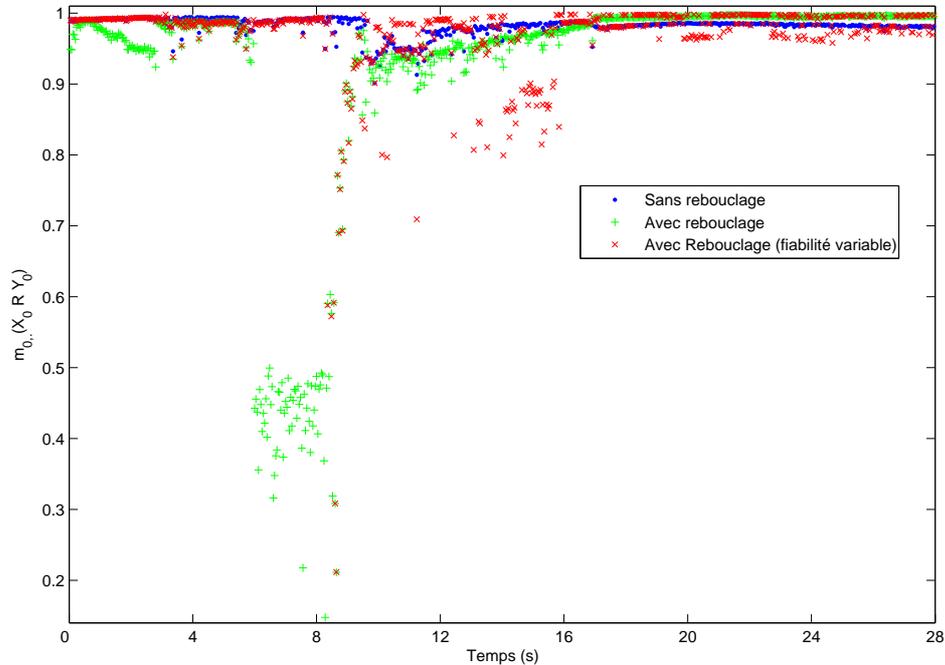


FIG. 4.30 – Evolution de la masse $m_{0,}(X_0 R Y_0)$ en utilisant une seule caméra et la prédiction comme second capteur.

Dans ce cas, on constate que le bouclage provoque une chute de la masse contrairement aux tests réalisés avec les données synthétiques (Sec. 4.1.3) qui permettaient d'améliorer le système. Nous avons aussi inclus le tracé du bouclage avec une fiabilité variable, dans ce cas, le jeu de masse issu de la prédiction n'est pas fusionné tel quel avec le jeu provenant des mesures capteurs. Le jeu de masse créé à partir des données prédites est affaibli par un coefficient, compris entre 0 et 1, en fonction de la qualité de la prédiction réalisée à l'instant précédent. C'est ce qui explique qu'avec cette méthode le bouclage provoque moins de chute de masse, lorsque la prédiction est mauvaise le jeu de masse qui en résulte est affaibli et donc la chute de masse est moins importante lors de la fusion. Si la prédiction est très mauvaise, le jeu de masse issu de la prédiction n'apporte alors plus aucune information supplémentaire pour la fusion.

De façon à confirmer l'intérêt de l'utilisation de la masse de prédiction, nous avons bouclé la prédiction en utilisant nos deux sources d'information (Fig. 4.31).

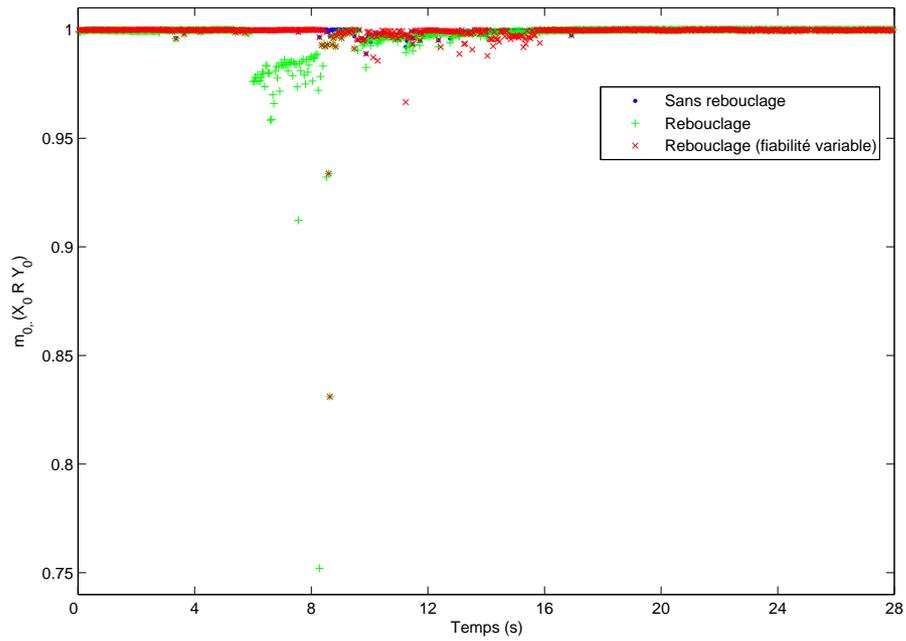


FIG. 4.31 – Evolution de la masse $m_{0,.(X_0 R Y_0)}$ en utilisant les deux sources d'information et la prédiction comme capteur supplémentaire.

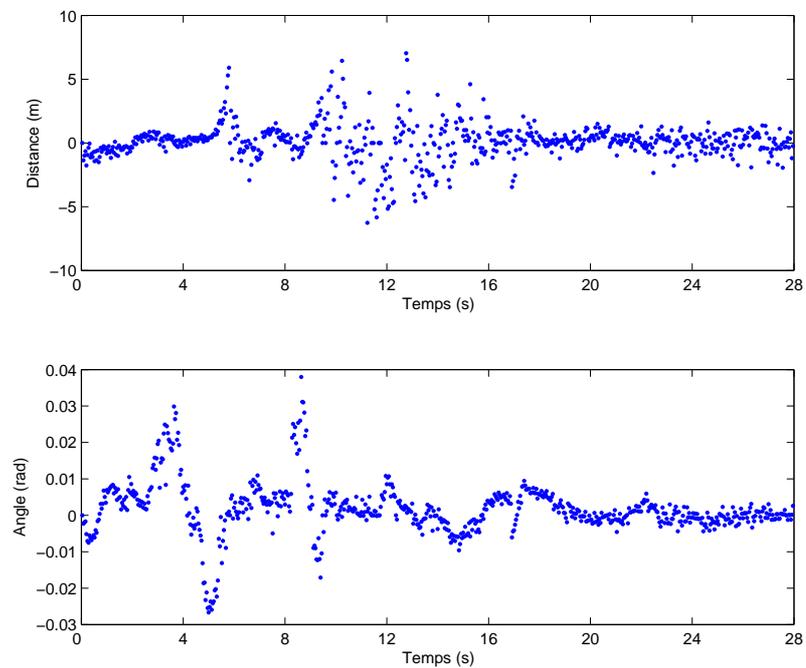


FIG. 4.32 – Erreur de prédiction sur la distance et sur l'angle avec le filtre Non Linéaire pour une prédiction à $t + dt$ seconde.

On constate que le bouclage de la prédiction provoque la plupart du temps une chute plutôt importante de la masse comme dans le cas où l'on avait qu'un seul capteur. On remarque cette fois aussi que l'introduction d'un coefficient de fiabilité sur le jeu de masse issue de la prédiction permet de limiter la chute de masse. Cependant, il n'y a que dans les intervalles $0-6s$, $9-11s$ et $25-28s$ que la masse issue du bouclage est supérieure à la masse sans bouclage. La masse sans bouclage étant déjà très élevée avec deux capteurs, on peut en déduire qu'utiliser la prédiction comme un capteur supplémentaire n'est pas judicieux dans ce cas, surtout si les valeurs de prédictions ne sont pas correctes. C'est d'ailleurs ce que l'on constate sur la figure Fig. 4.32 où l'on peut remarquer que la prédiction, surtout pour l'angle, est plutôt mauvaise. L'erreur maximale atteint environ $7m$ pour la distance et environ $0.04rad$ pour l'angle. Même si l'erreur globale de prédiction sur la distance paraît acceptable par moment, l'erreur de prédiction sur l'angle est souvent trop importante.

D'après ces expériences on peut en conclure que la prédiction ne peut être utilisée que si l'erreur de prédiction est très faible. Dans ce cas, la prédiction permet d'améliorer le suivi des objets. Cependant, le bouclage présente un intérêt uniquement dans le cas où l'on aurait un minimum de capteurs. En effet, la fusion avec 2 capteurs permet déjà d'obtenir une masse proche de 1, le bouclage devient alors inutile.

4.3 Conclusion

Dans ce chapitre, nous avons pu mettre en évidence les avantages de notre approche par rapport à celle proposée en 1998 par M. Rombaut. Pour cela, nous avons utilisé des données, tout d'abord synthétiques, puis réelles. Les données synthétiques nous ont servi à la mise au point de notre algorithme et à la réalisation des premiers tests. La robustesse des deux algorithmes d'association a ensuite été estimée en partant de données réelles fortement bruitées que nous avons nous même extraites d'un film réalisé à l'aide d'un simple caméscope numérique. De ces tests, nous avons pu constater que dans des conditions normales d'utilisation, les deux algorithmes d'associations offrent des résultats quasi similaires avec un léger avantage pour le notre. Cependant, nous avons pu remarquer que notre algorithme est plus robuste vis à vis de la fiabilité des données. En effet, contrairement à l'algorithme développé par M. Rombaut, il permet l'association d'objets jusqu'à des valeurs de fiabilité faible.

Nous avons envisagé dans cette partie de tirer profit de la prédiction de l'évolution de la trajectoire des objets. Pour cela nous avons créé des jeux masses à partir des prédictions de distance et d'angle pour chaque objet de la même façon que si ces données provenaient d'une source d'information supplémentaire. Les jeux de masses créés sont ensuite utilisés au moment de la fusion multicapteurs. On constate alors que cette méthode donne de bons résultats sur les données synthétiques. Cependant, il n'est possible de les utiliser avec des données réelles que si le nombre de capteurs est réduit et avec des algorithmes de filtrages performants permettant d'obtenir une prédiction de très bonne qualité. Dans le cas contraire, l'utilisation de cette information provoque une chute de la masse plus ou moins importante en fonction de la qualité de la prédiction. Nous avons alors appliqué un coefficient d'affaiblissement sur les jeux de masses issus de la prédiction. Ce coefficient est dépendant de la qualité de la prédiction de façon à pouvoir profiter de ces informations lorsqu'elles peuvent être utilisées et, à l'inverse, permettre de les rejeter si elles sont mauvaises.

Conclusion et perspectives

Tout système d'aide à la conduite comporte une phase de détection de l'environnement et des objets qui y sont présents. Dans ce mémoire, nous avons présenté un algorithme capable de détecter et de suivre des objets à partir de capteurs et proposé une méthode pour déterminer si certains d'entre eux constituent un danger ou non.

Le premier chapitre de ce mémoire détaille quelques uns des projets qui traitent du véhicule intelligent. L'état de l'art ainsi réalisé a permis de montrer différents projets traitant de la détection d'obstacles et d'introduire le projet RaViOLi dans lequel nous sommes intégrés. C'est dans le cadre de ce projet que nous avons développé l'algorithme d'association proposé dans ce mémoire. Le projet RaViOLi ayant pour but la détection à longue distance, ce choix impose de travailler avec des données moins fiables que si elles provenaient d'une distance plus courte. C'est sur la base de cette contrainte que nous avons développé l'algorithme d'association.

Le deuxième chapitre présente un rappel sur les outils mathématiques utilisés dans l'algorithme complet. Nous rappelons donc la théorie des fonctions de croyance, qui intervient dans la partie fusion pour l'algorithme d'association. Nous présentons aussi deux méthodes de filtrage prédictif : le filtre de Kalman linéaire et le filtre de Kalman étendu. Ces filtres prédictifs permettent de prédire l'évolution de la trajectoire des objets. Ces données sont ensuite exploitées de deux façons : tout d'abord, elles sont utilisées comme source d'information supplémentaire au niveau de la fusion multicapteurs, ensuite, elles sont aussi utilisées pour prévenir le conducteur d'une situation dangereuse.

Le chapitre 3 montre en détail le fonctionnement de l'algorithme complet. La première phase de cet algorithme traite les données grâce à la théorie des fonctions de croyance. Tout d'abord, en préparant les données, ce qui consiste à créer des jeux de masses séparément pour la distance et pour l'angle. Ensuite, nous combinons ces deux jeux de masses pour chacun des capteurs puis à fusionner le jeux résultant entre tous les capteurs. Enfin, vient une étape d'association, afin de déterminer si l'objet vient d'apparaître, si il a disparu ou bien si il est toujours dans le champs de vision des capteurs. L'étape d'association ayant déjà été réalisé par M. Rombaut, nous avons, dans un premier temps, utilisé cet algorithme. Cependant, celui-ci ne procurait pas des résultats satisfaisant lorsque les données

étaient moins fiables. Nous avons donc proposé une nouvelle formulation de cet algorithme d'association pour corriger ce problème. Par la suite, nous montrons un comparatif entre ces deux algorithmes d'association.

La seconde phase de l'algorithme complet consiste à effectuer deux prédictions de la trajectoire de chacun des objets détectés. La première, est calculée sur un laps de temps identique au temps d'échantillonnage des capteurs. Cette information est ré-utilisée comme une source d'information supplémentaire dans l'étape de fusion multicapteurs. La seconde est calculée sur un temps variable en fonction de la vitesse du véhicule de telle sorte qu'il soit possible de prévenir le conducteur à l'avance si un danger se présente. Dans ce chapitre, nous décrivons les modèles d'état ainsi que les différents paramètres qui permettent la prédiction des trajectoires pour les objets détectés.

Le dernier chapitre montre les résultats issus des tests en utilisant des données synthétiques puis réelles. Nous comparons, à l'aide de ces données, l'algorithme d'association de M. Rombaut à l'algorithme que nous proposons. Nous montrons aussi les avantages et les inconvénients d'utiliser les données prédites comme une source d'information supplémentaire au moment de la fusion.

Afin d'obtenir des données réelles, nous avons mis en place notre propre protocole expérimental. Les mesures ont été extraites à partir d'une scène de circulation routière. Les données résultantes de cette expérience sont très bruitées : environ 25% d'écart pour la distance et 200% pour l'angle entre une mesure et la suivante. Cependant, ces données sont réelles et elles permettent de juger de la robustesse de l'algorithme.

Dans ce mémoire, nous mettons en évidence que quelles que soient les données utilisées, notre étape d'association donne de meilleurs résultats que celle proposée M. Rombaut. Dans la plage d'utilisation que nous avons déterminé, le nombre de fausses associations est nul, et l'écart de masse séparant la bonne relation des autres est plus significatif. Cette partie pourra donc être utilisée pour l'étape de fusion et d'association du projet RaViOLi.

Nous avons montré que l'utilisation de la prédiction comme information supplémentaire n'est envisageable que si il n'y a que très peu de capteurs disponibles et que la prédiction est de bonne qualité. La fusion de deux capteurs concordants permet en effet d'obtenir une masse de relation proche de 1, si la prédiction n'est pas aussi bonne que les mesures, l'utilisation de cette information dégrade la masse d'association.

En ce qui concerne la prédiction à quelques secondes, les résultats que nous obtenons avec un simple filtre de Kalman montrent que cette prédiction n'est pas utilisable à moins d'avoir un algorithme prédictif plus performant. On peut aussi ajouter qu'il est plus facile de prédire loin et d'avoir des valeurs correctes si les données capteurs ne sont pas trop bruitées. Or, nous avons travaillé avec des données fortement bruitées.

On peut aussi ajouter que le traitement complet de l'algorithme prend $1ms$ pour 6 objets sur un Xéon $3.6GHz$ en programmation java sous Windows XP[®]. Sachant que cet algorithme peut être implanté sur une carte dédiée, il devrait donc être envisageable de faire fonctionner l'algorithme en temps réel.

Le travail concernant l'algorithme d'association peut être poursuivi. En effet, nous avons montré que la méthode d'association que nous proposons, équivaut à effectuer une fusion avec l'opérateur conjonctif, puis, à redistribuer les masses attribuées aux hypothèses composées sur les singletons en utilisant le principe de raison insuffisante. Cependant, nous avons réussi à démontrer cette propriété seulement pour un nombre fini d'objets. Nous ne sommes pas parvenu à démontrer la formulation de façon générale avec un nombre d'objet non limité. Cette démonstration est intéressante car cet algorithme permet de ne pas avoir à fusionner les masses 2 à 2, ce qui accroît rapidement le nombre d'hypothèses composées à calculer, mais il permet de calculer en une fois tous les singletons. L'algorithme d'association constitue en effet une méthode de fusion généralisée, à opérateur conjonctif, avec distribution pignistique.

Concernant la prédiction, il faudrait mettre en oeuvre des méthodes de filtrage plus performantes que le filtrage de Kalman tel que le filtrage particulière. Cette étape de prédiction permettra en effet de prévenir le conducteur si un objet à été analysé comme dangereux.

Annexe

Démonstration des formules d'association

Cette partie décrit la démonstration mathématique des nouvelles formules pour un nombre d'objets fini. En effet, nous n'avons pas pu démontrer ces formules pour un nombre d'objets quelconque. Afin de limiter la complexité des calculs, la démonstration ci-dessous est effectuée en prenant 3 objets et uniquement pour la fonction $m_{0,\cdot}$. Cependant, nous avons vérifié ces formules sur papier jusque 10 objets pour les deux fonctions de croyances $m_{i,\cdot}$ et $m_{\cdot,j}$.

En prenant 3 objets connus (Y_0 , Y_1 et Y_2) et un objet perçu (X_0), le cadre de discernement se définit comme suit : $\Omega_{0,\cdot} = \{(X_0RY_0), (X_0RY_1), (X_0RY_2), (X_0R*)\}$. Les fonctions de croyance sont donc les suivantes :

$$\begin{array}{ccc} m_{0,0}(X_0RY_0) & m_{0,1}(X_0RY_1) & m_{0,2}(X_0RY_2) \\ m_{0,0}(\overline{X_0RY_0}) & m_{0,1}(\overline{X_0RY_1}) & m_{0,2}(\overline{X_0RY_2}) \\ m_{0,0}(\Omega_{0,\cdot}) & m_{0,1}(\Omega_{0,\cdot}) & m_{0,2}(\Omega_{0,\cdot}) \end{array}$$

les nouvelles formules d'association pour le jeu de masse $m_{i,\cdot}$ permettent d'arriver au résultat suivant :

$$m_{0,\cdot}(X_0RY_0) = K_{0,\cdot} \cdot [m_{0,0}(X_0RY_0) \cdot (1 - m_{0,1}(X_0RY_1)) \cdot (1 - m_{0,2}(X_0RY_2)) + \frac{1}{3} \cdot m_{0,1}(\overline{X_0RY_1}) \cdot m_{0,0}(\Omega_{0,\cdot}) \cdot m_{0,2}(\Omega_{0,\cdot}) + \frac{1}{3} \cdot m_{0,2}(\overline{X_0RY_2}) \cdot m_{0,0}(\Omega_{0,\cdot}) \cdot m_{0,1}(\Omega_{0,\cdot}) + \frac{1}{2} \cdot m_{0,1}(\overline{X_0RY_1}) \cdot m_{0,2}(\overline{X_0RY_2}) \cdot m_{0,0}(\Omega_{0,\cdot})]$$

$$m_{0,\cdot}(X_0RY_1) = K_{0,\cdot} \cdot [m_{0,1}(X_0RY_1) \cdot (1 - m_{0,0}(X_0RY_0)) \cdot (1 - m_{0,2}(X_0RY_2)) + \frac{1}{3} \cdot m_{0,0}(\overline{X_0RY_0}) \cdot m_{0,1}(\Omega_{0,\cdot}) \cdot m_{0,2}(\Omega_{0,\cdot}) + \frac{1}{3} \cdot m_{0,2}(\overline{X_0RY_2}) \cdot m_{0,0}(\Omega_{0,\cdot}) \cdot m_{0,1}(\Omega_{0,\cdot}) + \frac{1}{2} \cdot m_{0,0}(\overline{X_0RY_0}) \cdot m_{0,2}(\overline{X_0RY_2}) \cdot m_{0,1}(\Omega_{0,\cdot})]$$

$$m_{0,\cdot}(X_0RY_2) = K_{0,\cdot} \cdot [m_{0,2}(X_0RY_2) \cdot (1 - m_{0,0}(X_0RY_0)) \cdot (1 - m_{0,1}(X_0RY_1)) + \frac{1}{3} \cdot m_{0,0}(\overline{X_0RY_0}) \cdot m_{0,1}(\Omega_{0,\cdot}) \cdot m_{0,2}(\Omega_{0,\cdot}) + \frac{1}{3} \cdot m_{0,1}(\overline{X_0RY_1}) \cdot m_{0,0}(\Omega_{0,\cdot}) \cdot m_{0,2}(\Omega_{0,\cdot}) + \frac{1}{2} \cdot m_{0,0}(\overline{X_0RY_0}) \cdot m_{0,1}(\overline{X_0RY_1}) \cdot m_{0,2}(\Omega_{0,\cdot})]$$

$$m_{0,\cdot}(X_0R*) = K_{0,\cdot} \cdot [m_{0,0}(\overline{X_0RY_0}) \cdot m_{0,1}(\overline{X_0RY_1}) \cdot m_{0,2}(\overline{X_0RY_2}) + \frac{1}{3} \cdot m_{0,0}(\overline{X_0RY_0}) \cdot m_{0,1}(\Omega_{0,\cdot}) \cdot m_{0,2}(\Omega_{0,\cdot}) + \frac{1}{3} \cdot m_{0,1}(\overline{X_0RY_1}) \cdot m_{0,0}(\Omega_{0,\cdot}) \cdot m_{0,2}(\Omega_{0,\cdot}) + \frac{1}{3} \cdot m_{0,2}(\overline{X_0RY_2}) \cdot m_{0,0}(\Omega_{0,\cdot}) \cdot m_{0,1}(\Omega_{0,\cdot}) + \frac{1}{2} \cdot m_{0,0}(\overline{X_0RY_0}) \cdot m_{0,1}(\overline{X_0RY_1}) \cdot m_{0,2}(\Omega_{0,\cdot}) + \frac{1}{2} \cdot m_{0,0}(\overline{X_0RY_0}) \cdot m_{0,2}(\overline{X_0RY_2}) \cdot m_{0,1}(\Omega_{0,\cdot}) + \frac{1}{2} \cdot m_{0,1}(\overline{X_0RY_1}) \cdot m_{0,2}(\overline{X_0RY_2}) \cdot m_{0,0}(\Omega_{0,\cdot})]$$

$$m_{0,\cdot}(\Omega_{0,\cdot}) = K_{0,\cdot} \cdot m_{0,0}(\Omega_{0,\cdot}) \cdot m_{0,1}(\Omega_{0,\cdot}) \cdot m_{0,2}(\Omega_{0,\cdot})$$

$$(K_{0,\cdot}) = \frac{1}{[(1 - m_{0,0}(X_0RY_0)) \cdot (1 - m_{0,1}(X_0RY_1)) \cdot (1 - m_{0,2}(X_0RY_2))] \cdot [1 + \frac{m_{0,0}(\overline{X_0RY_0})}{1 - m_{0,0}(X_0RY_0)} + \frac{m_{0,1}(\overline{X_0RY_1})}{1 - m_{0,1}(X_0RY_1)} + \frac{m_{0,2}(\overline{X_0RY_2})}{1 - m_{0,2}(X_0RY_2)}]}$$

La probabilité pignistique se déduit facilement de cette fonction de croyance :

$$\begin{aligned}
BetP(\{X_0 RY_0\}) &= m_{0,\cdot}(X_0 RY_0) + \frac{1}{4} \cdot m_{0,\cdot}(\Omega_{0,\cdot}) \\
BetP(\{X_0 RY_1\}) &= m_{0,\cdot}(X_0 RY_1) + \frac{1}{4} \cdot m_{0,\cdot}(\Omega_{0,\cdot}) \\
BetP(\{X_0 RY_2\}) &= m_{0,\cdot}(X_0 RY_2) + \frac{1}{4} \cdot m_{0,\cdot}(\Omega_{0,\cdot}) \\
BetP(\{X_0 R*\}) &= m_{0,\cdot}(X_0 R*) + \frac{1}{4} \cdot m_{0,\cdot}(\Omega_{0,\cdot})
\end{aligned}$$

Nous allons maintenant effectuer la fusion de façon classique en utilisant l'opérateur conjonctif de Dempster. On commence donc par fusionner les deux premiers jeux de masses, puis on fusionne le résultat avec le troisième :

$$m_1 = m_{0,0} \oplus m_{0,1}$$

$$m_2 = m_1 \oplus m_{0,2}$$

Voici ce que l'on obtient pour m_1 :

$$\begin{aligned}
m_1(X_0 RY_0) &= K_1 \cdot m_{0,0}(X_0 RY_0) \cdot (1 - m_{0,1}(X_0 RY_1)) \\
m_1(X_0 RY_1) &= K_1 \cdot m_{0,1}(X_0 RY_1) \cdot (1 - m_{0,0}(X_0 RY_0)) \\
m_1(\overline{X_0 RY_0}) &= K_1 \cdot m_{0,0}(\overline{X_0 RY_0}) \cdot m_{0,1}(\Omega_{0,\cdot}) \\
m_1(\overline{X_0 RY_1}) &= K_1 \cdot m_{0,1}(\overline{X_0 RY_1}) \cdot m_{0,0}(\Omega_{0,\cdot}) \\
m_1((X_0 RY_2) \cup (X_0 R*)) &= K_1 \cdot m_{0,0}(\overline{X_0 RY_0}) \cdot m_{0,1}(\overline{X_0 RY_1}) \\
m_1(\Omega_{0,\cdot}) &= K_1 \cdot m_{0,0}(\Omega_{0,\cdot}) \cdot m_{0,1}(\Omega_{0,\cdot}) \\
K_1 &= \frac{1}{1 - m_{0,0}(X_0 RY_0) \cdot m_{0,1}(X_0 RY_1)}
\end{aligned}$$

En utilisant la masse m_1 qui vient d'être calculée, en excluant le coefficient K_1 ⁽³⁾. En notant le conflit $k_1 = m_{0,0}(X_0 RY_0) \cdot m_{0,1}(X_0 RY_1)$ on peut en déduire m_2 :

$$\begin{aligned}
m_2(X_0 RY_0) &= K_2 \cdot m_1(X_0 RY_0) \cdot (1 - m_{0,2}(X_0 RY_2)) \\
m_2(X_0 RY_1) &= K_2 \cdot m_1(X_0 RY_1) \cdot (1 - m_{0,2}(X_0 RY_2)) \\
m_2(X_0 RY_2) &= K_2 \cdot m_{0,2}(X_0 RY_2) \cdot (1 - m_1(X_0 RY_0) - m_1(X_0 RY_1)) \\
m_2(\overline{X_0 RY_0}) &= K_2 \cdot m_1(\overline{X_0 RY_0}) \cdot m_{0,2}(\Omega_{0,\cdot}) \\
m_2(\overline{X_0 RY_1}) &= K_2 \cdot m_1(\overline{X_0 RY_1}) \cdot m_{0,2}(\Omega_{0,\cdot}) \\
m_2(\overline{X_0 RY_2}) &= K_2 \cdot m_{0,2}(\overline{X_0 RY_2}) \cdot m_1(\Omega_{0,\cdot}) \\
m_2((X_0 RY_0) \cup (X_0 R*)) &= K_2 \cdot m_1(\overline{X_0 RY_1}) \cdot m_{0,2}(\overline{X_0 RY_2}) \\
m_2((X_0 RY_1) \cup (X_0 R*)) &= K_2 \cdot m_1(\overline{X_0 RY_0}) \cdot m_{0,2}(\overline{X_0 RY_2}) \\
m_2((X_0 RY_2) \cup (X_0 R*)) &= K_2 \cdot m_1((X_0 RY_2) \cup (X_0 R*)) \cdot m_{0,2}(\Omega_{0,\cdot}) \\
m_2(X_0 R*) &= K_2 \cdot m_1((X_0 RY_2) \cup (X_0 R*)) \cdot m_{0,2}(\overline{X_0 RY_2}) \\
m_2(\Omega_{0,\cdot}) &= K_2 \cdot m_1(\Omega_{0,\cdot}) \cdot m_{0,2}(\Omega_{0,\cdot}) \\
K_2 &= \frac{1}{1 - k_1 - m_1(X_0 RY_0) \cdot m_{0,2}(X_0 RY_2) - m_1(X_0 RY_1) \cdot m_{0,2}(X_0 RY_2)}
\end{aligned}$$

³Il est préférable de normaliser une seule fois à la fin de toutes les étapes de fusion pour éviter de propager des erreurs numériques.

En prenant le jeu de masses m_2 , on calcule la probabilité pignistique :

$$\begin{aligned}
BetP(\{X_0RY_0\}) &= m_2(X_0RY_0) + \frac{1}{3} \cdot m_2(\overline{X_0RY_1}) + \frac{1}{3} \cdot m_2(\overline{X_0RY_2}) + \frac{1}{2} \cdot m_2((X_0RY_0) \cup (X_0R*)) + \frac{1}{4} \cdot m_2(\Omega_{0,.}) \\
BetP(\{X_0RY_1\}) &= m_2(X_0RY_1) + \frac{1}{3} \cdot m_2(\overline{X_0RY_0}) + \frac{1}{3} \cdot m_2(\overline{X_0RY_2}) + \frac{1}{2} \cdot m_2((X_0RY_1) \cup (X_0R*)) + \frac{1}{4} \cdot m_2(\Omega_{0,.}) \\
BetP(\{X_0RY_2\}) &= m_2(X_0RY_2) + \frac{1}{3} \cdot m_2(\overline{X_0RY_0}) + \frac{1}{3} \cdot m_2(\overline{X_0RY_1}) + \frac{1}{2} \cdot m_2((X_0RY_2) \cup (X_0R*)) + \frac{1}{4} \cdot m_2(\Omega_{0,.}) \\
BetP(\{X_0R*\}) &= m_2(X_0R*) + \frac{1}{3} \cdot m_2(\overline{X_0RY_0}) + \frac{1}{3} \cdot m_2(\overline{X_0RY_1}) + \frac{1}{3} \cdot m_2(\overline{X_0RY_2}) + \frac{1}{2} \cdot m_2((X_0RY_0) \cup (X_0R*)) \\
&\quad + \frac{1}{2} \cdot m_2((X_0RY_1) \cup (X_0R*)) + \frac{1}{2} \cdot m_2((X_0RY_2) \cup (X_0R*)) + \frac{1}{4} \cdot m_2(\Omega_{0,.})
\end{aligned}$$

Maintenant, on remplace les valeurs de masses m_2 par celles calculées précédemment. On s'aperçoit alors que les probabilités pignistique obtenues sont identiques que l'on choisisse l'une ou l'autre des deux méthodes. Cependant, on remarque que le nombre de termes intermédiaires à calculer est inférieur avec nos formules ce qui évite une explosion combinatoire.

Bibliographie

- [1] Observatoire national interministériel de sécurité routière. Les accidents corporels de la circulation routière : bilan de l'année 2005. Technical report, Janvier 2006.
- [2] M. Rombaut. Fusion : état de l'art et perspective. Technical report, IUT de Troyes, LM2S-UTT, October 2001.
- [3] D. Lefée. *Contribution à la réalisation d'un capteur de vision 3D pour systèmes embarqués : coopération entre traitements passifs pour la détection des piétons dans un environnement urbain*. PhD thesis, Institut National des Sciences Appliquées de Rouen, Juillet 2005.
- [4] T. Kato, Y. Ninomiya, and I. Masaki. An obstacle detection method by fusion of radar and motion stereo. *IEEE Transactions on Intelligent Transportation Systems*, 3(3) :182–188, September 2002.
- [5] D. Gruyer, C. Royère, R. Labayrade, and D. Aubert. Credibilistic multi sensor fusion for real time application. application to obstacle detection and tracking. *IEEE International Conference on Advanced Robotics, ICAR'2003, University of Coimbra, Portugal*, June 2003.
- [6] D.Gruyer, C.Royère, and V. Cherfaoui. Credibilist multi-sensors fusion for the mapping of dynamic environnement. In *Thrid International Conference on Information Fusion (FUSION'2000)*, page TuC2, 2000.
- [7] M. El Badaoui El Najjar. *Localisation dynamique d'un véhicule sur une carte routière numérique pour l'assistance à la conduite*. PhD thesis, Université de Technologie de Compiègne, Décembre 2003.
- [8] S. Izri. *Architecture de fusion de données pour le suivi dynamique de véhicule*. PhD thesis, Université de Picardie Jules Verne, Novembre 2005.
- [9] S. Mammar, S. Glaser, and M. Netto. Integrated longitudinal and lateral control. In *12th ITS World Congress*, November 2005.

- [10] K.Ch. Fuerstenberg. Intersafe overview. In *8th International Conference on Intelligent Transportation System (ITSC'05)*, September 2005.
- [11] A. Broggi, M. Bertozzi, A. Fascioli, C.G.L. Bianco, and A. Piazzzi. Visual perception of obstacles and vehicles for platooning. *IEEE Transactions on Intelligent Transportation Systems*, 1(3) :164–176, September 2000.
- [12] G. Toulminet, A. Broggi, A. Bensrhair, M. Bertozzi, P. Miché, and S. Mousset. Système de stéréovision pour la détection d'obstacles et de véhicules en temps réel. In *18eme Colloque sur le traitement du signal et des images, GRETSI'01*, page cdrom, Septembre 2001.
- [13] G. Toulminet. *Extraction des contours 3D des obstacles par stéréovision pour l'aide à la conduite automobile*. PhD thesis, Institut National des Sciences Appliquées de Rouen, 2002.
- [14] A. Bensrhair, M. Bertozzi, A. Broggi, P. Miché, S. Mousset, and G. Toulminet. A cooperative approach to vision based vehicle detection. In *IEEE International Conference on Intelligent Transportation Systems, ITSC'01*, pages 209–214, August 2001.
- [15] H. Weisser, P. Schulenberg, R. Bergholz, and U. Lages. Autonomous driving on vehicle test tracks : overview, motivation and concept. In *IEEE Conference on Intelligent Vehicle*, pages 439 – 443, 1998.
- [16] C. Stiller, J. Hipp, C. Rössig, and A. Ewald. Multi-sensor obstacle detection and tracking. *Image and Vision Computing*, 18 :389–396, 1999.
- [17] M. Bertozzi, A. Broggi, and A. Fascioli. Vision-based intelligent vehicles : state of the art and perspectives. *Elsevier Robotics and Autonomus Systems*, 32(1) :1–16, June 2000.
- [18] A. Menhaj, J. Assaad, P. Deloof, and M. Heddebaut. Enhancing safety on road with on board microwave anticollision system by combining two radar sensors. In *3rd World Congress on Intelligent Transport Systems (ITS)*, October 1996.
- [19] M. Saint-Venant, J. Assaad, and M. Heddebaut. A numerical correlator receiver based radar. In *32th International Symposium on Automotive Technology and Automation (ISATA)*, pages 437–443, 14- 18 June 1999.
- [20] J. Pontois. *Conception d'un système permettant la détection d'obstacles à l'avant d'un véhicule routier*. PhD thesis, Université des Sciences et Technologies de Lille, Mars 2000.

- [21] J.M. Blosseville, M. Cottinet, C. Laugeau, J.M. Martins Da Cruz, F. Nashashibi, and F. Petit. Exploration dans l'univers de prometheus. Technical report, INRETS, Novembre 1996.
- [22] D. Gruyer, C. Royère, and V. Cherfaoui. Utilisation de la théorie des croyances pour l'association dans le suivi de cible. *Technique et Science Informatiques (TSI)*, 22 :983–1010, 2003.
- [23] Y. Bar-Shalom. *Multitarget-multisensor tracking : applications and advances*, volume 3. 2000.
- [24] C. Royère, D. Gruyer, and V. Cherfaoui. Identification d'objets par la combinaison d'experts à l'aide de la théorie de l'évidence. In *Rencontre Francophone sur la Logique Floue et Ses Applications LFA '2000*, pages 237–244, Octobre 2000.
- [25] M. Delplanque. *L'application des techniques modernes de traitement de l'information pour le guidage de véhicules sous-marins*. PhD thesis, USTL, 1998.
- [26] S. Gattein and P. Vannoorenberghe. A comparative analysis of two approaches using the road network for tracking ground targets. In Per Svensson and Johan Schubert, editors, *Proceedings of the Seventh International Conference on Information Fusion*, volume I, pages 62–69, Mountain View, CA, June 2004. International Society of Information Fusion.
- [27] B. Pannetier, K. Benameur, V. Nimier, and M. Rombaut. Use map information for a ground target tracking. In *International Society of Information Fusion (ISIF)*, July 2005.
- [28] Y. Bar-Shalom and X.R. Li. *Multitarget-Multisensor tracking*. Y. Bar-Shalom, 1995.
- [29] D.B. Reid. An algorithm for tracking multiple targets. *IEEE Transaction on Automatic Control*, AC-24(6) :843–854, 1979.
- [30] A. Dempster. Upper and lower probabilities induced by multivalued mapping. *Annals of Mathematical Statistics*, AMS-38 :325–339, 1967.
- [31] G. Shafer. *A Mathematical Theory of Evidence*. Princeton University Press, Princeton, New Jersey, 1976.
- [32] P. Smets. What is dempster-shafer's model? In R.R. Yager, M. Fedrizzi, and J. Kacprzyk, editors, *Advances in the Dempster-Shafer Theory of Evidence*, pages 5–34. Wiley, 1994.

- [33] P. Smets and R. Kennes. The transferable belief model. *Artificial Intelligence*, 66(2) :191–234, 1994.
- [34] R. Kennes and P. Smets. *Uncertainty in Artificial Intelligence*, chapter Computational aspect of the Möbius transformation, pages 401–416. Elsevier Science Publishers, 1991.
- [35] R. Kennes. Computational aspects of the möbius transformation of graphs. *IEEE Transactions on Systems, Man and Cybernetics*, 22 :201–223, 1992.
- [36] P. Smets. The combination of evidence in the transferable belief model. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 12(5) :447–458, 1990.
- [37] L. Zadeh. Fuzzy sets and information granularity. In R.K. Ragade, M.M. Gupta, and R.R. Yager, editors, *Advances in Fuzzy Sets Theory and Applications*, pages 3–18. North-Holland Publishing Co., 1979.
- [38] R.R. Yager. On the dempster-shafer framework and new combination rules. *Information Sciences*, 41 :93–138, 1987.
- [39] D. Dubois and H. Prade. A set-theoric view of belief functions : Logical operations and approximations by fuzzy sets. *International Journal of General Systems*, 12 :193–226, 1986.
- [40] E. Lefevre, O. Colot, P. Vannoorenberghe, and D. de Brucq. Informations et combinaison : les liaisons conflictuelles. *Revue Traitement du Signal*, 18(3) :161–177, 2001.
- [41] E. Lefevre, O. Colot, and P. Vannoorenberghe. Belief function combination and conflict management. *Information Fusion*, 3(2) :149–162, 2002.
- [42] R.O. Duda and P.E. Hart. *Pattern Classification and Scene Analysis*. John Wiley & Sons, New-York, 1973.
- [43] C.K. Chow. An optimum character recongnition system using decision functions. *R. E. Transactions on Electronic Computers*, pages 247–254, 1957.
- [44] B. Dubuisson. *Diagnostic et Reconnaissances de Formes*. Hermes, 1990.
- [45] P. Smets. Data fusion in the transferable belief model. In *Third International Conference on Information Fusion (FUSION'2000)*, pages PS 21–33, 2000.
- [46] M. Degroot. *Optimal Statistical Decisions*. McGraw-Hill, New York, 1970.

- [47] P. Smets. Constructing the pignistic probability function in a context of uncertainty. In M. Henrion, R. D. Schachter, L.N. Kanal, and J.F. Lemmer, editors, *Uncertainty in Artificial Intelligence 5*, pages 29–40, Amsterdam, 1990. North-Holland.
- [48] P. Smets. Decision making in the TBM : the necessity of the pignistic transformation. *International Journal of Approximate Reasoning (IJAR)*, 38 :133–147, February 2005.
- [49] A. Appriou. Probabilités et incertitude en fusion de données multi-senseurs. *Revue Scientifique et Technique de la Défense*, 11 :27–40, 1991.
- [50] A. Nifle and R. Reynaud. Un argument pour le choix entre décision pignistique et maximum de plausibilité en théorie de l'évidence. In *Seizième Colloque GRETSI*, pages 1411–1414, Grenoble, 1997.
- [51] W.F. Caselton and W. Luo. Decision making with imprecise probabilities : Dempster-shafer theory and application. *Water Resources Research*, 28(12) :3071–3083, 1992.
- [52] T. Denoeux. Analysis of evidence-theoretic decision rules for pattern classification. *Pattern Recognition*, 30(7) :1095–1107, 1997.
- [53] I. Bloch and H. Maître. Fusion de données en traitement d'images : Modèles d'informations et décisions. *Revue Traitement du Signal*, 11 (Numéro Spécial : Fusion de données)(6) :435–446, 1994.
- [54] G.J. Klir. *Measures of Uncertainty in the Dempster-Shafer Theory of Evidence*, pages 35–49. *Advances in the Dempster-Shafer Theory of Evidence*. John Wiley and Sons, New York, R.R. Yager and M. Fedrizzi and J. Kacprzyk edition, 1994.
- [55] A. Ramer. Uniqueness of information measure in the theory of evidence. *Fuzzy Sets and Systems*, 24(2) :183–196, 1987.
- [56] G. Klir and A. Ramer. Uncertainty in the Dempster-Shafer theory : a critical re-examination. *International Journal of General Systems*, 18(2) :155–166, 1990.
- [57] Karin Dahia. *Nouvelles méthodes en filtrage particulière. Application au recalage de navigation inertielle par mesures altimétriques*. PhD thesis, Université Joseph Fourier, Janvier 2005.
- [58] R.E. Kalman. A new approach to linear filtering and prediction problems. *Transaction of the ASME - Journal of basic engineering*, 82 :35–45, 1960.
- [59] A. Getout-Petit. Approximate filter for the conditional law of partially observed process in non linear filtering. *SIAM journal on control and optimization*, 36(4) :1423–1447, 1998.

- [60] J. Kohlas and P. A. Monney. *A mathematical theory of hints. An approach to Dempster-Shafer theory evidence*. Springer-Verlag, 1995.
- [61] M. Rombaut and V. Cherfaoui. Decision making in data fusion using Dempster-Shafer's theory. In *3th IFAC Symposium on Intelligent Components and Instrumentation for Control Applications*, Annecy, France, 9-11 June 1997.
- [62] P. Vannoorenberghe and T. Denoeux. Likelihood-based vs. distance-based evidential classifiers. In *10th international conference on Fuzzy Systems FUZZ-IEEE'2001*, 2001.
- [63] T. Denoeux. A k-nearest neighbour classification rule based on Dempster-Shafer theory. *IEEE Transactions on Systems, Man and Cybernetics*, 25(5) :804–813, 1995.
- [64] M. Rombaut. Decision in multi-obstacle matching process using the theory of belief. In *AVCS'98*, pages 63–68, 1998.
- [65] M. Dahamani, A. Meche, H. Benoudnine, M. Keche, and A. Ouamri. Poursuite d'une cible manoeuvrante en utilisant l'algorithme dcimm. In *Conference Internationale sur les Systèmes de Télécommunications (CISTEMA'2003)*, Septembre 2003.
- [66] Y. Lemeret, E. Lefevre, and D. Jolly. Simulator of obstacle detection and tracking. In G. Attiya and Y. Hamam, editors, *5th EUROSIM Congress on Modelling and Simulation*, September 2004.
- [67] J.C. Noyer. *Traitement non linéaire du signal radar par filtrage particulaire*. PhD thesis, Université Paul Sabatier, Décembre 1996.
- [68] N.J. Gordon, D.J. Salmond, and A.F.M. Smith. Novel approach to non linear / non gaussian bayesian state estimation. *IEEE Proceedings-F*, 140(2), April 1993.
- [69] P. Del Moral. *Résolution particulaire des problèmes d'estimation et d'optimisation non linéaire*. PhD thesis, Univeristé Paul Sabatier, Toulouse, 1994.
- [70] M. Isard and A. Blake. Condensation - conditionnal density propagation for visual tracking. *International Journal of Computer Vision*, 1998.

Bibliographie de l'auteur

Publication dans des revues

1. Y. Lemeret, E. Lefevre, D. Jolly, Improvement of an association algorithm for obstacle tracking, *IEEE Information Fusion*, à paraître, 2006.

Conférences internationales

1. Y. Lemeret, E. Lefevre, D. Jolly, Simulator of obstacle detection and tracking, *5th EUROSIM Congress on Modelling and Simulation*, Septembre 2004, Marne la Vallée.
2. Y. Lemeret, E. Lefevre, D. Jolly, Evidence theory for data fusion in transportation systems, *International Federation of Automatic Control*, pp. 81-86, Octobre 2004, Bulgarie.
3. Y. Lemeret, E. Lefevre, D. Jolly, Detection and tracking of moving objects, *IEEE sponsored international conference on Artificial Intelligence Systems (AIS)*, Septembre 2005, Russie.
4. Y. Lemeret, E. Lefevre, D. Jolly, Tracking cars and prediction of their trajectories, *IEEE sponsored International Conference on Machine Intelligence (ACIDCA-ICMI)*, pp. 64-69, Novembre 2005, Tunisie.
5. Y. Lemeret, E. Lefevre, D. Jolly, An association algorithm for tracking multiple moving objects, *IEEE Intelligent Transportation Systems Conference (ITSC2006)*, Septembre 2006, Canada.

Conférences nationales

1. Y. Lemeret, E. Lefevre, D. Jolly, Fusion de données provenant d'un laser et d'un radar en utilisant la théorie de Dempster-Shafer, *MajecSTIC04*, Octobre 2004, Calais.
2. Y. Lemeret, E. Lefevre, D. Jolly, Association d'objets, *SEE : Théorie des fonctions de croyances - de nouveaux horizons pour l'aide à la décision*, Décembre 2005, Paris.