



HAL
open science

Calcul de trajectoires pour la préconisation de manoeuvres automobiles sur la base d'une perception multi-capteur : application à l'évitement de collision

Adam Houenou

► **To cite this version:**

Adam Houenou. Calcul de trajectoires pour la préconisation de manoeuvres automobiles sur la base d'une perception multi-capteur : application à l'évitement de collision. Autre [cs.OH]. Université de Technologie de Compiègne, 2013. Français. NNT : 2013COMP2121 . tel-00977389

HAL Id: tel-00977389

<https://theses.hal.science/tel-00977389>

Submitted on 11 Apr 2014


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

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

Par Adam HOUENOU

Calcul de trajectoires pour la préconisation de manœuvres automobiles sur la base d'une perception multi-capteur : application à l'évitement de collision

Thèse présentée
pour l'obtention du grade
de Docteur de l'UTC



Soutenue le 09 décembre 2013
Spécialité : Technologies de l'Information et des Systèmes

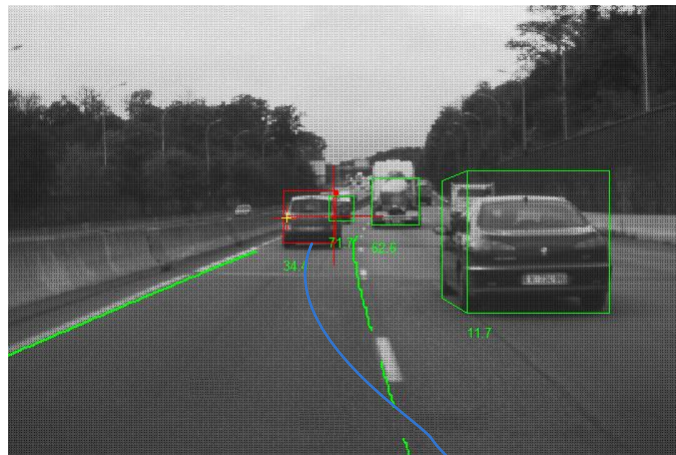
D2121

Thèse de doctorat de l'Université de Technologie de
Compiègne
Champ disciplinaire : Technologies de l'Information et des
Systèmes

Calcul de trajectoires pour la préconisation de manœuvres automobiles sur la base d'une perception multi-capteur

Application à l'évitement de collision

Adam HOUÉNOU



Thèse soutenue le Lundi 9 Décembre 2013 devant le jury composé de :

Rapporteurs :	Thierry Fraichard	INRIA
	Laurent Trassoudaine	Institut Pascal
Examineurs :	Bernard Dubuisson	HEUDIASYC
	Fawzi Nashashibi	INRIA
Encadrant entreprise :	Stéphane Géronimi	PSA Peugeot Citroën
Directeurs de thèse :	Philippe Bonnifait	HEUDIASYC
	Véronique Cherfaoui	HEUDIASYC

Remerciements

Ces trois années de thèse ont été ponctuées de moments très enthousiastes et de moments plus laborieux pendant lesquels j'ai reçu le soutien chaleureux de nombreuses personnes. Je voudrais remercier ici toutes ces personnes qui ont participé de près ou de loin à l'accomplissement de mes travaux.

Je tiens particulièrement à remercier mes directeurs de thèse M. Philippe Bonnifait et Mme Véronique Cherfaoui qui ont été bien au delà de leur rôle d'encadrants et qui sont devenus de très bons amis. Je les remercie de m'avoir conseillé et guidé dans mes travaux de recherche et d'avoir su m'indiquer l'état d'esprit à adopter pendant les périodes difficiles. J'ai énormément appris d'eux, tant professionnellement que personnellement, leur savoir-faire et leur passion dans leurs diverses activités sont un véritable modèle pour moi.

Je remercie très sincèrement M. Stéphane Géronimi et M. Jean-François Boissou, mes encadrants du côté de PSA Peugeot Citroën, pour m'avoir fait confiance après mon stage de fin d'étude au sein l'équipe et de l'avoir maintenue pendant toute la durée de la thèse. Leur implication, leur disponibilité et leur soutien pendant la thèse ont été plus que précieux.

Merci à mes camarades doctorants du laboratoire Heudiasyc pour tous ces bons moments passés ensemble, pour les échanges instructifs que nous avons eus et aussi pour le soutien moral qu'apporte le groupe.

Merci au personnel du laboratoire et aux collègues de chez PSA pour l'accueil chaleureux auquel j'ai eu droit et pour la bonne ambiance.

Je remercie les membres rapporteurs de mon jury de thèse pour l'attention particulière avec laquelle ils ont lu mon travail ainsi que tous les membres du jury en général, pour leurs diverses critiques qui ont contribué à améliorer mon mémoire et pour leur appréciation finale.

Je remercie très affectueusement ma chère mère qui a tant prié pour que tout se passe bien et qui m'a tout le temps encouragé.

Je remercie chaleureusement Diane Bijou pour sa tendresse et ses petits soins.

En bon croyant, je ne manquerai pas de remercier le Seigneur sans Qui rien de tout ceci ne se serait passé. Je Le remercie de m'avoir prêté force et santé pendant cette période et d'avoir fait que tout se passe pour le mieux.

Résumé

Les systèmes d'aide à la conduite, en général, et plus particulièrement les systèmes d'aide à l'évitement de collision sont de plus en plus présents dans les véhicules car ils ont un très fort potentiel de réduction du nombre d'accidents de la circulation. En effet, ces systèmes ont pour rôle d'assister le conducteur, voire de se substituer à lui lorsque la situation de conduite indique un risque de collision important. Cette thèse traite du développement de ces systèmes en abordant quelques problématiques rencontrées.

Afin de réagir convenablement, le système a d'abord besoin d'une représentation aussi fidèle que possible de l'environnement du véhicule. La perception est faite au moyen de capteurs extéroceptifs qui permettent de détecter les objets et d'en mesurer divers paramètres selon leur principe de mesure. La fusion des données individuelles des capteurs permet d'obtenir une information globale plus juste, plus certaine et plus variée. Ce travail traite en profondeur des méthodes de suivi d'objets par fusion de données multi-capteur, multimodale au niveau piste. Les approches proposées ont été évaluées puis approuvées grâce à des données de roulage réel et sur des données de conduite simulées.

Il est ensuite nécessaire de faire une analyse de la scène perçue au cours du temps afin d'évaluer le risque de collision encouru par le véhicule porteur du système. Cette thèse propose des méthodes de prédiction de trajectoire et de calcul de probabilité de collision, à divers horizons temporels afin de quantifier le risque de collision et d'établir ainsi divers niveaux d'alerte au conducteur. Un simulateur de scénarios automobiles a été utilisé pour valider la cohérence des méthodes d'analyse de scène.

Enfin, lorsque le risque de collision atteint un seuil jugé critique, le système doit calculer une trajectoire d'évitement de collision qui sera ensuite automatiquement exécutée. Les principales approches de planification de trajectoires ont été revues et un choix a été fait et motivé en accord avec le contexte de système d'aide à la conduite.

Table des matières

1	Introduction générale	1
1.1	Contexte	1
1.2	ADAS	2
1.3	Systèmes d'aide à l'évitement de collision	4
1.3.1	Situations accidentelles	4
1.3.2	Étude des manœuvres d'évitement de collision	5
1.3.3	Détermination des données nécessaires à l'exécution des manœuvres	6
1.4	Sujet de thèse et organisation du mémoire	7
2	Système de calcul de manœuvres d'évitement de collision	11
2.1	Introduction	11
2.2	Présentation du système	11
2.2.1	Entrées/sorties du système	12
2.2.2	Gestion matérielle des capteurs	13
2.2.3	Système de Perception	15
2.2.4	Module d'analyse de scène	16
2.2.5	Module de décision	17
2.3	Repère de travail	18
2.3.1	Modèles de représentation d'objet	18
2.3.2	Impact du repère de travail sur le modèle d'évolution	20
2.3.3	Problème de la conversion des mesures de capteurs vers un repère fixe	23
2.3.4	Choix d'une approche	25
2.4	Moyens d'évaluation des approches	27
2.4.1	Plateforme expérimentale	27
2.4.2	Simulateur de données de conduite automobile	30
2.5	Conclusion	35
3	Fusion de pistes de capteurs de modalités différentes	37
3.1	Introduction	37
3.2	Alignement des données des capteurs	39
3.2.1	Alignement spatial	39
3.2.2	Alignement temporel	39
3.3	Architecture temporelle de fusion	41
3.3.1	Cas de l' <i>out-of-sequence</i>	42

3.3.2	Fusion asynchrone de données	43
3.3.3	Fusion synchrone de données	44
3.3.4	Choix d'une stratégie	45
3.4	Association de pistes locales	47
3.4.1	Approches mono-hypothèse	48
3.4.2	Architectures d'association de données multi-capteur	50
3.4.3	Proposition d'une méthode d'association	51
3.5	Estimation d'état de pistes globales	58
3.5.1	Fusion multi-capteur par filtrage de Kalman	59
3.5.2	Fusion de pisteurs	61
3.5.3	Intersection de covariance	62
3.5.4	Approche choisie	64
3.6	Estimation des paramètres non cinématiques	64
3.6.1	Inférence bayésienne	65
3.6.2	Mécanisme de vote	66
3.7	Gestion de la confiance en l'existence des pistes globales	66
3.7.1	Score de Sittler	67
3.7.2	Machine à états	69
3.8	Résultats et analyses	71
3.8.1	Évaluation de l'association et de la fusion de pistes sur des données simulées	71
3.8.2	Évaluation sur des données réelles pré-enregistrées	76
3.9	Conclusion	80
4	Analyse de scènes dynamiques	83
4.1	Introduction	83
4.2	Prédiction de trajectoire basée sur un modèle de mouvement	85
4.3	Modélisation de la route	87
4.4	Module de Reconnaissance de Manœuvre	88
4.4.1	État de l'art	88
4.4.2	Approche proposée	90
4.5	Prédiction de trajectoire basée sur la reconnaissance de manœuvre	93
4.5.1	Repère de Frenet le long d'une ligne	93
4.5.2	Prédiction d'un ensemble de trajectoires possibles	96
4.5.3	Sélection de la meilleure trajectoire	100
4.6	Combinaison des deux trajectoires prédites	101
4.7	Calcul de risque de collision	102
4.7.1	Notion de risque de collision	102
4.7.2	État de l'art	103
4.7.3	Méthode proposée	105
4.8	Résultats d'expérimentation et analyses	111
4.8.1	Reconnaissance de manœuvre et prédiction de trajectoire	111
4.8.2	Calcul de risque de collision	116
4.9	Conclusion	121

5	Conclusions et perspectives	127
5.1	Conclusions	127
5.2	Perspectives	128
5.2.1	Détermination de la manœuvre d'évitement de collision	129
5.2.2	Perspectives à plus long terme	136
6	Annexes	137
6.1	Situations accidentelles	137
6.2	Notions de changements de repère	139
6.2.1	Théorèmes	140
6.2.2	Transformation du repère mobile \mathcal{M} au repère fixe \mathcal{F}	142
6.2.3	Transformation du repère fixe \mathcal{F} au repère mobile \mathcal{M}	147
6.3	Équations d'un modèle de mouvement à vitesse de lacet et à accélération tangentielle constantes	151
6.4	Modèles cinématiques dans un repère égo-centré	153
6.4.1	Modélisation du mouvement de l'égo-véhicule	153
6.4.2	Modèle cinématique	156
6.5	Déformation d'une trajectoire	159
	Bibliographie	161
	Liste des symboles	167

Table des figures

1.1	Exemples de véhicules autonomes. a) Véhicule vainqueur du Urban Challenge. b) Un véhicule autonome Google.	2
1.2	L'augmentation du nombre de capteurs ouvre de nouvelles perspectives	4
1.3	Quelques situations accidentelles	5
1.4	Provenance de l'obstacle heurté par un véhicule	7
2.1	Représentation schématique du système	12
2.2	Un exemple d'architecture avec deux bus CAN	14
2.3	Couche capteur du système.	15
2.4	Exemple de système de perception multi-capteur, multimodal	16
2.5	Modèle ponctuel d'objet	19
2.6	Modèle char, très utilisé pour les véhicules	19
2.7	Perception du mouvement d'un véhicule cible se déplaçant en ligne droite lors d'un dépassement par l'égo-véhicule.	21
2.8	Conversion d'état entre repère fixe et repère mobile	23
2.9	Annulation de la dérive de l'égo-localisation par redéfinition de l'origine du repère fixe	26
2.10	Le repère de travail est fixe, mais son origine est redéfini périodiquement à la position de l'égo-véhicule afin d'annuler la dérive d'égo-localisation accumulée.	27
2.11	Schéma de montage des capteurs sur le véhicule expérimental. (a) Peugeot 407 SW. (b) Vue approximative des champs de perception des capteur	28
2.12	Un exemple de route simulée, avec plusieurs sections de chaussées droites, un rond point et une intersection	31
2.13	Exemple de trajectoire de changement de voie déformée suivant la courbure de la voie. En haut, la trajectoire obtenue en supposant que la route est rectiligne et en bas, le résultat de la déformation pour un rayon de courbure égal à 150m	33
3.1	Architecture de fusion de données niveau piste	38
3.2	Représentation de deux séries de mesures en décalage temporel.	40
3.3	Illustration de l'out-of-sequence.	42
3.4	Fusion asynchrone. Les données sont fusionnées au fur et à mesure de leur réception.	44

3.5	Fusion synchrone. Synchronisation des données par extrapolation de la dernière sortie de chaque capteur. Ici l'une des sorties du Capteur 3 a été extrapolée deux fois	45
3.6	Cas d'école avec 3 capteurs et deux pistes. L'association de données, matérialisée par une ellipse, se fait indépendamment entre les pistes locales de chaque capteur et les pistes globales du système.	50
3.7	L'association de données se fait directement entre toutes les pistes locales de tous les capteurs et toutes les pistes globales du système . .	50
3.8	Les pistes locales des capteurs sont d'abord associées entre elles (a) pour former des super-observations qui sont ensuite associées avec les pistes globales du système (b)	51
3.9	Association de pistes en considérant l'historique	52
3.10	Exemple d'association de pistes.	56
3.11	Les ellipses de P (en tirets) obtenues pour diverses valeurs de P_{ab} sont toujours contenues dans la zone d'intersection des ellipses de P_a et P_b (en traits continus). Pour $P_{ab} = 0$, i.e. sous hypothèse d'indépendance, on obtient l'ellipse en trait gras.	62
3.12	Les ellipses de P (en tirets) obtenues quelques soit la valeurs de $\omega \in [0, 1]$ englobent toujours la zone d'intersection des ellipses de P_a et P_b (en traits continus).	63
3.13	Machine à états pour la gestion de pistes	69
3.14	Aperçu du scénario simulé, avec les 5 véhicules et une représentation des champs de perception des capteurs	72
3.15	Erreurs d'association. Les cibles réelles sont représentées en noir et les pistes capteur en couleur. a) Permutation de groupe b) Plus de groupes que de cibles c) Moins de groupes que de pistes	74
3.16	Comparaison des erreurs du suivi global et celles des suivi individuels des capteurs	75
3.17	Interface de visualisation du scénario enregistré. Chaque couleur représente un capteur. Les lignes magenta représentent les points de contour des objets pistés par le lidar, les losanges verts représentent les pistes du radar et les rectangles cyans représentent les pistes de la caméra. Les symboles dessinés en noirs sont les objets détectés par les capteurs et identifiés comme immobiles.	76
3.18	La vérification des résultats se fait à partir de la visualisation des pistes locales des capteurs (a), des super-observations (b), des pistes globales confirmées (c) et de la vidéo témoin (d). FP désigne un Faux Positif, obtenu ici par la caméra, et qui est ensuite supprimé des pistes globales par gestion de la confiance	77
3.19	Exemple de scénario de test de l'association de pistes locale et de la gestion de la confiance des piste globales. A gauche la vue réelle, au milieu la représentation des pistes des capteurs et à droite les pistes globales confirmées obtenues.	79
3.20	Véhicule suivi au cours des essais	80

3.21	Courbes de mesures obtenues : (a) Séparation longitudinale. (b) Vitesse longitudinale relative	81
4.1	Prédictions de trajectoire erronées car le modèle de prédiction, supposant un mouvement à vitesse de lacet constante n'est pas adapté à la manœuvre en cours.	84
4.2	Architecture du Module d'Analyse de Scène	85
4.3	Modélisation standard de la route par polylignes	87
4.4	Trajectoire dans le repère de Frenet	94
4.5	Trajectoire dans un repère cartésien, sur une route droite	97
4.6	Trajectory generation and selection.	101
4.7	Fonction de pondération $f(t)$	102
4.8	(a) En considérant une variance constante, la probabilité de collision peut être sous estimée. Ici, elle apparait nulle. (b) Lorsque la variance croît au fil du temps, on voit que le risque de collision n'est pas nul.	104
4.9	Illustration de la propagation d'incertitude le long de la trajectoire prédite. Les ellipses représentent l'incertitude, la courbe verte représente la trajectoire discrète prédite et la courbe bleue représente la trajectoire réelle.	108
4.10	Détection de collision entre deux véhicules	109
4.11	Tracés des 236 trajectoires de changement de voies enregistrées	112
4.12	Exemple de prédictions de trajectoire à différents instants lors d'un changement de voie à gauche.	114
4.13	Exemple de prédictions de trajectoire à différents instants lors d'un changement de voie à droite	115
4.14	Évolution de la probabilité de collision avec chaque véhicule : Scénario 1, jusqu'à $t=5.7s$	118
4.15	Évolution de la probabilité de collision avec chaque véhicule : Scénario 1, jusqu'à $t=6.4s$	119
4.16	Évolution de la probabilité de collision avec chaque véhicule : Scénario 1, jusqu'à $t=7.4s$	120
4.17	Évolution de la probabilité de collision avec chaque véhicule : Scénario 2, jusqu'à $t=8.2s$	122
4.18	Évolution de la probabilité de collision avec chaque véhicule : Scénario 2, jusqu'à $t=10.4s$	123
4.19	Évolution de la probabilité de collision avec chaque véhicule : Scénario 2, jusqu'à $t=11.3s$	124
5.1	Illustration de l'ICS. Si l'égo-véhicule se retrouve dans la zone triangulaire en fond gris, la collision sera inévitable	130
5.2	Scénarios de collision considérés. L'objet à éviter est dessiné en rouge et l'égo-véhicule en noir. (a) l'objet se trouve initialement dans la même voie que l'égo-véhicule. (b) l'objet s'insère dans la voie de l'égo-véhicule	131

Table des figures

5.3	Génération de chemins pour déterminer la manœuvre d'évitement de collision par déport latéral	135
6.1	Conversion d'état entre repère fixe et repère mobile	140
6.2	Mouvement de l'égo-véhicule	154
6.3	Déformation d'un quadrillage orthonormal (a) pour obtenir un quadrillage curviligne (b).	159

Chapitre 1

Introduction générale

1.1 Contexte

La question de l'amélioration de la sécurité des usagers de la route est un enjeu majeur de société depuis bien des décennies et est encore au cœur des préoccupations sociétales car les accidents de la circulation causent chaque année encore, de nombreux décès et blessures graves dans le monde. Grâce aux nombreuses avancées technologiques et aux nouvelles normes de sécurité qui rendent les véhicules et la conduite de plus en plus sûrs, le nombre d'accidents a une tendance générale à la baisse. Toutefois, d'après les chiffres de la sécurité routière en France, par exemple, en 2011, il y a eu jusqu'à 3963 personnes tuées sur les routes. Les statistiques montrent que les facteurs humains (seuls ou en combinaison avec d'autres facteurs) sont en cause dans 83% des accidents [Elslande, 2006]. Malgré l'établissement de règles de conduite de plus en plus strictes et l'installation d'importants dispositifs de contrôle, il est difficile voire impossible de s'assurer que le comportement des usagers reste exemplaire. Les messages de prévention routière pour sensibiliser les usagers sont très importants mais ont un effet probablement limité.

D'autres solutions possibles, pour améliorer la sécurité routière, sont par exemple l'automatisation totale de la conduite ou l'installation de Systèmes d'Aide à la Conduite (ADAS¹) qui assistent le conducteur et le préviennent, voire se substituent à lui lorsqu'il se met dans des situations potentiellement accidentogènes, afin de l'en sortir.

Le cas de la conduite automatique implique par définition que toute erreur liée à un facteur humain serait supprimée. La conduite en serait plus sûre puisque les règles imposées seraient mieux respectées par les véhicules autonomes et qu'en mode coopératif, les interactions entre véhicules seraient plus sécurisées. En cas de danger imprévisible, les temps de réaction seraient optimisés ou en tout cas mieux maîtrisés par rapport à une conduite humaine où il peut être très variable suivant les individus et suivant leur état. En dehors de cet aspect, le développement massif de

1. Advanced Driver Assistance System

véhicules autonomes aura de nombreux avantages économiques, sociétaux et environnementaux [Silberg and Wallace, 2012]. Il reste toutefois à relever les nombreux défis scientifiques et technologiques que cela implique. Le “Urban Challenge”, compétition de véhicules autonomes (Fig. 1.1.a) dans un environnement urbain “maîtrisé”, tenue à Victorville en Californie en 2007 et organisée par le DARPA¹, a joué un rôle important dans l’avancement des recherches sur les véhicules autonomes. Le projet “Google self-driving car” (Fig. 1.1.b) a officiellement franchi un pas important en Mai 2012 avec un premier permis de rouler pour véhicule autonome, dans l’état du Nevada aux États-Unis. Il ne s’agit toutefois, pour l’instant, que d’un permis pour effectuer librement des tests. Malgré un engouement certain pour leur développement, l’avènement des véhicules autonomes impliquerait des changements importants dans tout l’écosystème des transports [Silberg and Wallace, 2012] et prendra certainement du temps à se réaliser. Cependant, les recherches conduites dans le domaine des véhicules autonomes (appelés parfois “autonomobiles”) ont de nombreuses retombées pour les ADAS.




Figure 1.1: Exemples de véhicules autonomes. a) Véhicule vainqueur du Urban Challenge. b) Un véhicule autonome Google.

1.2 ADAS

L’intégration massive des ADAS dans les véhicules est une solution, pour l’instant, plus abordable que l’avènement des véhicules autonomes. Plusieurs études [Louwerse and Hoogendoorn, 2004] [Lundgren and Tapani, 2006][Golias et al., 2002] montrent qu’ils ont un impact important sur la réduction du nombre d’accidents de la circulation. Il en existe déjà de nombreux sur le marché ; il s’agit pour beaucoup de systèmes de sécurité active, c’est-à-dire à but préventif. Il y a, par exemple, l’ESP (Electronic Stability Program) qui aide au maintien de la contrôlabilité du véhicule dans les virages, l’ACC (Adaptive Cruise Control) qui aide à réguler la vitesse du véhicule afin de maintenir une distance de sécurité raisonnable par rapport au véhicule précédent, l’AEBS (Advanced Emergency Braking System) qui permet de freiner automatiquement lorsqu’une collision est imminente ou encore le LKA

1. US Defense Advanced Research Projects Agency

(Lane Keeping Assist ou LDW, Lane Departure Warning) qui prévient le franchissement involontaire d'une ligne de démarcation de voie. Le tableau 1.1 montre un exemple de chiffres publiés [Louwerse and Hoogendoorn, 2004] pour quelques catégories d'ADAS.

Catégories d'ADAS	Taux de réduction d'accident	
	Section de route	Intersection
Contrôle longitudinal	17%	8%
Contrôle latéral	10%	1%
Contrôle général	21%	10%
Évitement de collision	37%	65%
Perception de l'état de la surface de la route	7%	3%

Table 1.1: Impact des ADAS sur la réduction du nombre d'accidents de la circulation

On note que les fonctions d'évitement de collision font évidemment partie des plus utiles et également des plus prometteuses en matière d'impact sur la réduction du nombre d'accidents. Elles sont nécessairement basées sur la perception de l'environnement extérieur du véhicule puisqu'aucune manœuvre ne peut être préconisée, ni automatiquement exécutée sans avoir une connaissance assez précise de la configuration de cet environnement. Dans les applications automobiles embarquées, la perception est par défaut faite à l'aide de capteurs extéroceptifs qui recueillent divers types d'informations sur l'environnement, suivant leur principe de mesure. Toutefois, on peut étendre la notion de capteur à d'autres types d'équipements. Par exemple, la localisation sur une carte numérique grâce à un dispositif GPS¹ permet d'obtenir certaines caractéristiques de la section de route actuelle ou à venir du véhicule. Les dispositifs de communication véhicule-à-véhicule et véhicule-à-infrastructure (Car-to-X) qui en sont encore à une phase expérimentale, permettent également de recueillir de nombreuses données transmises par les véhicules ou infrastructures connectés. La grande majorité des ADAS déjà commercialisés à ce jour, n'utilisent qu'un seul capteur extéroceptif; en général un capteur radar. Ceci limite les performances recherchées car la variété des informations qu'on peut recueillir est limitée par le principe de mesure du capteur en question. D'autre part, la précision des capteurs n'est pas toujours satisfaisante, à moins d'investir dans un capteur coûteux; il en résulte une confiance faible sur les données recueillies et par conséquent une difficulté à décider d'une action. On remarque toutefois que la tendance à coupler plusieurs capteurs est amorcée. A titre d'exemple, la nouvelle Volvo S60 allie les performances d'une caméra et d'un radar pour détecter et reconnaître les piétons afin effectuer un arrêt d'urgence si nécessaire [Coelingh et al., 2010]. Le radar détecte la présence et la distance des obstacles pendant que la caméra en identifie

1. Global Positioning System

la nature. Le groupe Daimler annonce également que la future Mercedes classe S pourra être équipée de 6 radars, d'une caméra stéréo, de 12 capteurs ultrason, de 2 caméras infrarouge et de 4 caméras monovision [Mer, 2012a, Mer, 2012b]. Ceci ouvre de nouvelles possibilités en matière de performances et de fonctionnalités (voir figure 1.2¹). En effet la fusion de donnée multi-capteur multimodale permet d'obtenir un champ global de perception plus large, d'accroître la confiance des mesures dans les secteurs de redondance et d'avoir des types d'informations plus variés.

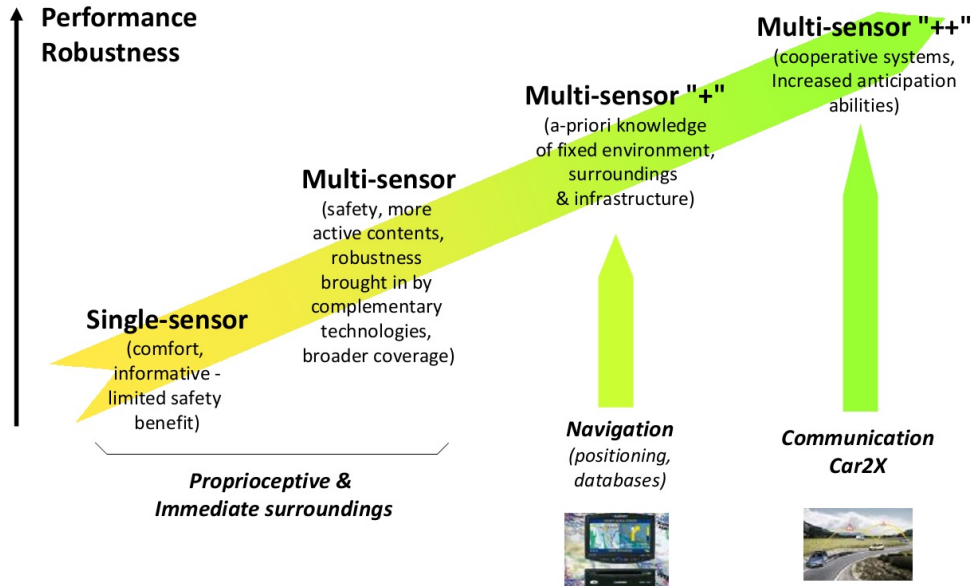


Figure 1.2: L'augmentation du nombre de capteurs ouvre de nouvelles perspectives

1.3 Systèmes d'aide à l'évitement de collision

Les systèmes d'aide à l'évitement de collision sont conçus pour prévenir le conducteur, voire pour intervenir sur les commandes du véhicule lorsqu'un risque important de collision est détecté. Ils aident ainsi à éviter la collision ou à mitiger ses conséquences. Ce sont en général des fonctionnalités d'urgence et non des fonctionnalités de confort. Leur conception passe par l'étude des situations accidentelles.

1.3.1 Situations accidentelles

D'après le rapport du CEESAR² et du LAB³ sur les situations accidentelles en France métropolitaine en 2008 [Sit, 2008], une situation accidentelle désigne la si-

1. Source : PSA Peugeot Citroën
2. Centre Européen d'Étude de Sécurité et d'Analyse des Risques
3. Laboratoire d'Accidentologie, de Biomécanique et d'étude du comportement humain

tuation à laquelle est confronté un conducteur au moment de l'accident. Elle caractérise les circonstances dans lesquelles le véhicule a été accidenté. Une situation accidentelle est donc reliée à un conducteur et à son véhicule et non à l'accident en lui-même. Il a été relevé jusqu'à 49 différentes situations accidentelles qui sont regroupées en 4 catégories ci-après.

- Les situations relatives aux pertes de contrôle et aux problèmes de guidage. Ce groupe rassemble les impliqués seuls en cause et les impliqués heurtant un autre véhicule suite à un déport ou une sortie de voie. Ils sont majoritairement responsables de l'accident selon les forces de l'ordre.
- Les situations relatives aux conducteurs accidentés en intersection. Les situations accidentelles de ce groupe concernent les conducteurs impliqués en intersection, avec deux usagers dans l'accident.
- Les situations relatives aux accidents de piétons. C'est l'action du piéton codée dans les BAAC¹ qui détermine principalement la situation attribuée au véhicule et non la manœuvre réalisée par ce dernier.
- Les situations relatives aux conducteurs accidentés en section courante, sans piéton, ni problème de perte de contrôle ou de guidage. Dans cette classe sont regroupés les conducteurs impliqués dans un accident à deux usagers, sans piéton et hors intersection.

Le détail des situations accidentelles relatives à chaque catégorie est reporté en annexe (section 6.1). Les pictogrammes de la figure 1.3 relatent certains scénarios d'accidents.




Figure 1.3: Quelques situations accidentelles

1.3.2 Étude des manœuvres d'évitement de collision

L'étude des différentes situations accidentelles permet de se rendre compte que pour la plupart des cas relevés, il est possible d'éviter la collision annoncée en exécutant à temps, certaines manœuvres qui varient selon la situation. Les cas de collision suite à une perte de contrôle du véhicule sont par définition plus difficiles à maîtriser. La solution est de prévenir les pertes de contrôle du véhicule, ce qui sort du cadre

1. Bulletin d'Analyse d'Accident Corporel

de cette thèse. Pour les autres situations, l'ensemble des manœuvres d'évitement de collision identifiées peut être résumé comme ceci :

- Freinage sur la même voie jusqu'à à l'arrêt total
- Freinage sur la même voie sans arrêt total
- Évitement de l'obstacle en se déportant à gauche
- Évitement de l'obstacle en se déportant à droite
- Retour à la voie initiale de conduite (ou non-changement de voie)
- Accélération sur la même voie
- Marche arrière sur la même voie.

Les manœuvres ainsi identifiées sont des classes d'actions qui peuvent chacune correspondre à plusieurs trajectoires. La trajectoire précise dépend de la configuration de scène et de l'état de l'égo-véhicule¹. Un même type de manœuvre peut correspondre à plusieurs situations accidentelles et une même situation accidentelle peut admettre plusieurs possibilités de manœuvres d'évitement de collision.

1.3.3 Détermination des données nécessaires à l'exécution des manœuvres

Avant d'entamer une manœuvre d'évitement de collision, il est nécessaire d'avoir prévu cette collision et d'identifier à quel moment elle risque le plus de se produire. Pour ce faire, il faut connaître un certain nombre de paramètres qui décrivent la configuration de la scène ainsi que l'état de l'égo-véhicule. Ces mêmes paramètres sont utiles pour faire le choix de la manœuvre adéquate et pour calculer la trajectoire précise correspondant à cette manœuvre. Deux principales catégories de données ont été identifiées :

- Les données sur l'infrastructure routière
 - nombre de voies de la chaussée
 - largeur des voies de la chaussée
 - géométrie des voies (courbe décrite)
 - sens de circulation sur les voies adjacentes
 - niveau d'adhérence de la chaussée (au moins qualitatif)
 - informations liées à la navigation : vitesses limites, autorisation de dépasser etc.
 - largeur de l'accotement
 - etc.
- Les données sur les objets de la scène², y compris l'égo-véhicule
 - position, vitesse, accélération, lacet et vitesse de lacet, dans le repère considéré
 - dimensions (largeur, longueur)
 - type (piéton, deux roues, voiture, camion, animal, arbre...)
 - etc.

Cette liste, relativement exhaustive, représente un ensemble de données utiles à la détermination d'une manœuvre d'évitement de collision. Les données effectivement

1. Véhicule équipé du système étudié

2. Tout objet représentant un obstacle potentiel

disponibles dépendent des moyens de perception utilisés, notamment, le nombre de capteurs utilisés, leur nature et leur performance. Pour les données de nature numérique, il est nécessaire de recueillir la variance ou un niveau de confiance pour matérialiser leur imprécision.

La figure 1.4 montre la répartition de la provenance des objets heurtés suivant les secteurs du véhicule. Même si la majorité des collisions surviennent dans le secteur frontal, il est nécessaire d'avoir un champ de perception direct (zone couverte par un ou plusieurs capteurs) ou virtuel (estimation) sur toute la périphérie du véhicule afin d'éviter toute collision, quelle que soit sa provenance. Cela impose de monter les capteurs et autres équipements de perception de façon optimale sur l'égo-véhicule.




Figure 1.4: Provenance de l'obstacle heurté par un véhicule

1.4 Sujet de thèse et organisation du mémoire

La thèse faisant l'objet de ce mémoire, a été proposée par le constructeur automobile français, PSA Peugeot Citroën. Elle porte sur l'étude et la conception de Systèmes d'Aide à la Conduite (ADAS), plus précisément, les Systèmes d'Aide à l'Évitement de Collision (CAS¹). Les travaux ont été réalisés de façon mixte au Centre Technique de PSA à Vélizy-Villacoublay (Yvelines, 78) et au laboratoire Heudiasyc UMR CNRS 7253 de l'Université de Technologie de Compiègne (Oise, 60), du 27 Septembre 2010 au 26 Septembre 2013.

PSA, tout comme la plupart des constructeurs automobiles, dispose d'un département d'étude et de conception des systèmes d'aide à la conduite. Outre les raisons purement économiques et commerciales de leur engouement pour les ADAS, les acteurs du secteur automobile font de la sécurité des personnes, un facteur primordial lors de la conception des véhicules car les normes imposées deviennent de plus en plus strictes. Comme exemple récent, depuis le 24 Février 2013, 43 pays ont décidé

1. Collision Avoidance System

d'appliquer la réglementation n°13 de la Commission Économique des Nations Unies pour l'Europe rendant obligatoire la présence de l'AEBS (Système de Freinage Automatique) dans les camions et autocars ; l'objectif étant d'étendre cette réglementation aux autres catégories de véhicules [unece, 2008]. D'un point de vue plus large, l'évitement de collision basé sur la détection d'obstacles fait l'objet d'une attention particulière en ce moment et est grandement à l'étude.

Ce travail de recherche a pour objet l'étude des systèmes d'aide à l'évitement de collision. L'objectif est d'obtenir une application embarquée qui planifie une trajectoire d'évitement de collision lorsque le risque de collision est jugé important. Cette trajectoire est à terme destinée à être exécutée automatiquement. Toutefois, la commande des actionneurs du véhicule pour suivre au mieux cette trajectoire, ne fait pas partie des objectifs de la thèse.

Pour ce faire, plusieurs tâches principales ont été identifiées. D'abord, la perception de l'environnement doit fournir des informations assez riches et précises pour la représentation de la scène et une compréhension de la situation de conduite. Un des objectifs principaux est ainsi d'étudier un Système de Perception de l'environnement qui effectue le suivi des objets de la scène au cours du temps. Il est basé sur les données recueillies par un ensemble de capteurs montés sur le véhicule. Les capteurs automobiles sont de natures différentes (radar, caméra, lidar, ultrasons etc.) et sont, de plus en plus souvent, équipés d'un ordinateur dédié qui effectue le suivi des objets détectés dans leur champ de perception et qui fournit en sortie la liste de ses pistes locales¹ (smart sensors). Le Système de Perception étudié doit permettre l'ajout et la suppression de capteurs, quelle que soit leur nature, afin de s'adapter à des véhicules équipés différemment et de tolérer les pannes de capteur. Dans le contexte de cette étude, il est admis que tous les capteurs du système sont des *capteurs-pisteurs*, c'est-à-dire des capteurs qui font un pistage local des objets qu'ils ont détectés.

Ensuite, un Module d'Analyse de Scène se base sur cette perception pour évaluer le risque de collision encouru par l'égo-véhicule vis-à-vis des objets représentant un obstacle potentiel. Ceci passe par la prédiction des trajectoires des objets mobiles afin de prévoir d'éventuelles collisions avec la trajectoire prédite de l'égo-véhicule, sur un horizon de temps suffisant. D'un point de vue ADAS, l'objectif est d'alerter le conducteur proportionnellement à l'imminence d'une collision. Le risque de collision est donc évalué pour divers horizons de prédiction. On parle de risque de collision car les prédictions de trajectoires ne sont pas certaines ; il s'agit d'une estimation a priori de la trajectoire de chaque objet qui, de plus, est basée sur une perception de l'environnement, toujours entachée d'une certaine incertitude, si petite soit elle. Cela est la conséquence directe du bruit de mesure intrinsèquement liée aux équipements de perception.

1. Une piste correspond à la représentation interne d'un objet détecté et identifié au cours du temps

Lorsque le risque de collision pour un des objets détectés dépasse un seuil arbitrairement défini, un Module de Décision, basé sur les trajectoires prédites, détermine les différentes possibilités d'évitement de collision avec les trajectoires correspondantes. Les trajectoires d'évitement de collision admissibles doivent bien sûr être exemptes de tout autre risque important de collision. En cas de possibilités multiples le choix final doit être fait suivant des règles qu'il faut clairement définir.

Ce mémoire de thèse est organisé comme suit. Le chapitre 2 fait d'abord une présentation synoptique de l'application étudiée. Ses composantes principales et leurs interactions sont présentées. Les aspects matériels sont mis en évidence afin d'identifier clairement les entrées et les sorties du système. Puis, certains aspects fondamentaux, liés l'étude scientifique, sont présentés afin de préciser le contexte de travail dans les chapitres suivants du mémoire. Enfin, les moyens utilisés pour évaluer les différentes approches proposées au cours de l'étude sont présentés, notamment, la plateforme expérimentale de travail et un simulateur de données développé à ce propos.

Dans le chapitre 3, le module de suivi d'objets du Système de Perception est décrit en détails. Il revient sur les problématiques liées à la fusion de données multi-capteur, multimodale¹, niveau piste. Il rappelle quelques méthodes pertinentes rencontrées dans la littérature et explique celles que nous proposons. Enfin, les diverses expérimentations menées pour évaluer les approches sont expliquées et les résultats sont présentés et analysés.

Le Module d'Analyse de Scène est développé dans le chapitre 4. Des approches existant dans la littérature sur la prédiction de trajectoire de véhicules, y sont rappelées et discutées tandis que nous proposons une nouvelle méthode qui allie les avantages de deux grandes approches. Des méthodes d'estimation de la probabilité de collision et d'évaluation du risque de collision sont ensuite présentées. Le chapitre se termine sur l'évaluation des approches proposées et l'analyse des résultats obtenus.

La travaux sur la dernière partie de cette thèse, le Module de Décision, sont encore en cours et n'ont malheureusement pas encore abouti à des résultats présentables. Nous présenterons des approches possibles à ce sujet dans les perspectives de cette thèse. Cette discussion figurera dans le chapitre 5 qui conclut ce mémoire en rappelant les diverses contributions apportées.

1. Cet adjectif est utilisé dans tout le mémoire pour qualifier le fait que les capteurs utilisés sont de natures variées. Il n'est pas à confondre avec le caractère multimodal d'une distribution statistique par exemple.

Chapitre 2

Système de calcul de manœuvres d'évitement de collision

2.1 Introduction

Ce chapitre a pour but de présenter le synoptique de l'application ADAS développée, de définir certains paramètres fondamentaux (d'un point de vue scientifique) communs aux chapitres suivants et de présenter les moyens utilisés pour évaluer les solutions proposées dans la suite.

Le système complet est formé d'une partie matérielle (les capteurs, les calculateurs et leurs connexions) et d'une partie logicielle. Dans le contexte de ce mémoire, toute l'installation matérielle est supposée faite. Toutefois, à cause de certaines particularités voulues pour le Système de Perception, les aspects matériels sont en partie abordés. La partie logicielle comporte trois modules principaux qui sont en interaction. Les données d'entrées et les sorties des modules ainsi que les flux de données sont explicités.

Le repère de travail considéré durant toute l'étude scientifique est d'une importance cruciale car, de lui, dépendent les représentations et les divers formalismes utilisés. Nous allons discuter du choix d'un repère halo-centré c'est-à-dire fixe par rapport au sol ou d'un repère égo-centré, c'est-à-mobile avec l'égo-véhicule.

Enfin, ce chapitre présente les moyens mis en place pour évaluer les différentes approches proposées dans les chapitres suivants. Notamment, un véhicule expérimental et ses capteurs et un simulateur de données de conduite automobile.

2.2 Présentation du système

La figure 2.1 montre l'architecture globale de l'application développée. Elle présente trois composantes principales : le Système de Perception (SP), le Module d'Analyse de Scène (MAS) et le Module de Décision (MD). La fréquence de fonctionnement dépend de la fréquence des capteurs utilisés et de l'architecture de traitement choisie

pour le fonctionnement du Système de Perception. Cet aspect est discuté dans le chapitre suivant. A chaque itération générale, les tâches effectuées par chaque composante sont globalement séquentielles, selon le flux décrit par les flèches du schéma. Toutefois, de nombreuses tâches internes sont indépendantes et sont traitées en parallèle.

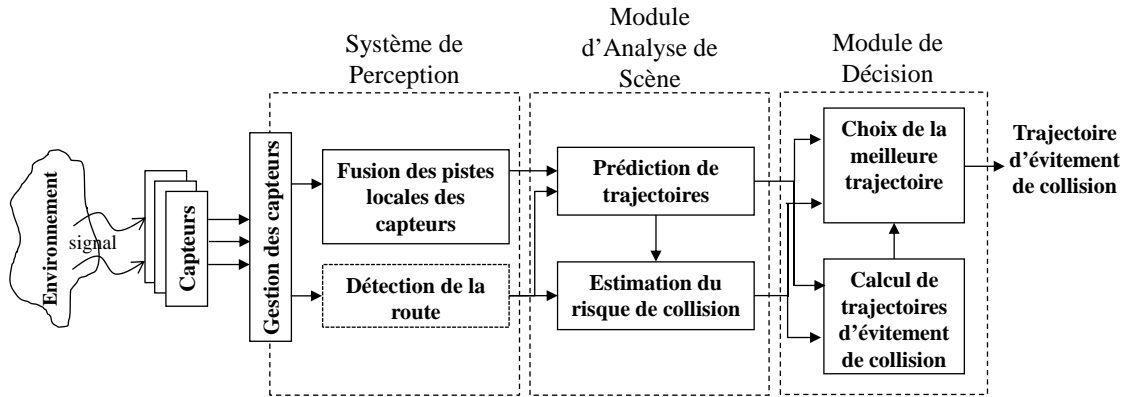


Figure 2.1: Représentation schématique du système

2.2.1 Entrées/sorties du système

Considérons plus en détails la figure 2.1. Les données d'entrée de l'application globale correspondent aux données d'entrées du SP et ne sont autres que les sorties des capteurs installés. Il s'agit d'une liste de pistes issues du suivi d'objets local effectué par chaque capteur. Les capteurs eux-mêmes ainsi que leurs calculateurs sont considérés comme des "boîtes noires", c'est-à-dire que nous ignorons les algorithmes et les paramètres des filtres mis en œuvre pour le suivi d'objets local qu'ils effectuent. Cette remarque importante justifie, plus tard, certains choix de méthodes. Les données fournies par les capteurs sont matériellement récupérées à travers le bus CAN¹ de l'égo-véhicule, sous forme de trames qui doivent être traitées afin de reconstituer la liste de pistes des capteurs, sous une forme exploitable. Un aspect fondamental voulu pour le système est qu'il doit être assez flexible pour permettre l'ajout et la suppression de capteurs à la plateforme sans nécessiter des modifications profondes. Ceci permet la tolérance aux pannes de capteurs et l'adaptation à des véhicules équipés différemment. Les performances seront inévitablement conditionnées par les capteurs présents. Le module de gestion matérielle des capteurs est présenté dans la section 2.2.2. Les sorties du Système de Perception sont une liste de *pistes globales* représentant l'ensemble des objets suivis par le système et un ensemble de données sur la géométrie de la route.

1. Controller Area Network : bus de transfert de données très répandu dans l'industrie automobile

Le MAS reçoit les données du SP, les traite et restitue les prédictions de trajectoire des objets suivis et de l'égo-véhicule. Il restitue également les estimations du risque de collision de ce dernier avec chaque objet relativement proche de lui, selon leurs futures trajectoires respectives.

Le MD reçoit à chaque itération les données du MAS et dès qu'il y a un objet pour lequel le risque de collision atteint le seuil critique arbitrairement défini, une manœuvre d'évitement de collision est calculée et restituée comme sortie du système. Cette dernière est fournie sous forme d'équations de courbe paramétrée en fonction du temps, dans un repère de travail sur lequel nous reviendrons par la suite.

D'un point de vue de l'aide à la conduite, il convient ensuite de transformer cette trajectoire en consignes de commande des actionneurs du véhicule. Ce point ne fait pas partie de ce travail de recherche.

2.2.2 Gestion matérielle des capteurs

Les capteurs utilisés ont chacun un ECU¹, un calculateur dédié qui effectue le traitement des données brutes du capteur. A chaque balayage, l'ECU a en charge la segmentation des données brutes afin de discerner les divers objets de la scène puis effectue un suivi d'objets local afin d'identifier chaque objet au cours du temps. La liste des pistes obtenues et la date des mesures sont encodées dans une série de trames qui sont ensuite émises sur l'un des bus CAN du véhicule. Le calculateur embarqué est connecté aux bus CAN et permet de récupérer les trames des divers capteurs et celles contenant les données proprioceptives de l'égo-véhicule (voir figure 2.2). Les données des capteurs peuvent être reconstitués à partir des trames reçues grâce aux instructions contenues dans la documentation des capteurs. Ces derniers étant totalement indépendants et potentiellement différents, ils ont chacun leurs propres instructions de décodage, leur propre repère de mesures, leur propre format de données ainsi que leur propre horloge pour la datation des données. Pour permettre l'ajout et la suppression de capteurs à la plateforme sans nécessiter de profonds changements, il est nécessaire d'harmoniser les données bas niveau (proche des capteurs) afin de conserver la même structure pour les traitements de niveaux plus hauts.

Un ensemble de traitements, appelé Couche Capteur (figure 2.3), se charge d'harmoniser les formats des données des capteurs et fait donc en sorte que le type des capteurs soit transparent, du point de vue de leur format de données, aux couches supérieures de traitement. Toutefois, des champs supplémentaires sont inclus au format commun, pour renseigner sur l'identité et les caractéristiques des capteurs à l'origine des données considérées. Ainsi, lorsque le nombre de capteur varie, cette information est connue et convenablement gérée dans les couches supérieures. Les données de chaque capteur physique sont gérées par un (PGC). Les PGC existent en

1. Electronic Control Unit




Figure 2.2: Un exemple d'architecture avec deux bus CAN

instances multiples et fonctionnent en parallèle au fur et à mesure que les capteurs émettent leurs données. Un PGC effectue les tâches suivantes :

- Extraction des données : elle consiste à intercepter toutes les trames CAN du capteur concerné puis à reconstituer son message, contenant la liste des pistes locales et la date de mesure.
- Validation des données : les propriétés du capteur sont exploitées pour éliminer dès le départ certaines données aberrantes ou clairement identifiées comme des artefacts de mesures. Certains capteurs peuvent être particulièrement touchés par ces phénomènes (données aberrantes et artefacts) et cette tâche devient cruciale pour réduire considérablement le nombre de calculs plus tard.
- Alignement spatial des données : il consiste à convertir les mesures de chaque capteur vers un repère commun. En effet chaque capteur a son propre repère de mesure et il est nécessaire de ramener leurs mesures dans le même référentiel afin de les fusionner. Les détails de cette opération sont décrits dans la section 3.2.1.
- Alignement temporel des données : il consiste à dater les mesures de chaque capteur dans la même base de temps. Cette opération est nécessaire pour garantir la cohérence temporelle tout au long des traitements. Nous en discutons plus loin dans la section 3.2.2.
- Alignement des formats de données : selon leur principe de fonctionnement, les capteurs ne mesurent pas tous les mêmes paramètres. Le format de données pour les pistes n'est donc pas le même pour chaque capteur. Cette tâche consiste à transcrire les données vers un nouveau format qui est l'union de tous les paramètres mesurés par l'ensemble des capteurs. Pour un paramètre non mesuré par un capteur donné, le champ correspondant est mis à une valeur NON_DISPONIBLE.
- Ajout de méta-données : malgré la flexibilité souhaitée en ce qui concerne la variabilité des capteurs, il est nécessaire de distinguer l'origine des données afin d'effectuer une fusion de données optimale. Un champ d'identification du capteur est donc inséré et permet de récupérer les caractéristiques qui lui sont propres.

Lorsqu'un capteur d'un nouveau genre est ajouté au système, il faut seulement déve-

ajouter un PGC supplémentaire lui correspondant. Si le capteur rajouté est identique à un des capteurs du système, le PGC correspondant est seulement dupliqué, avec un paramétrage différent.

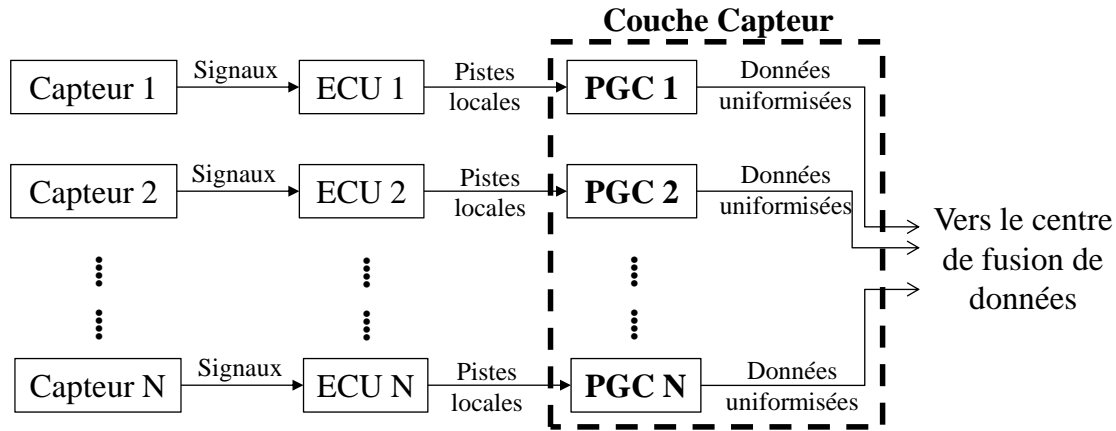


Figure 2.3: Couche capteur du système.

2.2.3 Système de Perception

Le Système de Perception de l'environnement du véhicule fournit les informations permettant de comprendre la situation de conduite. Les tâches effectuées incluent la détection et le suivi des objets de la scène grâce à la fusion des données des capteurs utilisés. Ces capteurs sont de types variés et l'architecture du système doit permettre l'ajout et la suppression de capteurs sans distinction de leur principe de mesure afin de s'adapter à divers niveaux d'équipement. La figure 2.4 montre un exemple d'architecture matérielle étudiée dans ce mémoire.

Dans le contexte de cette thèse, tous les capteurs utilisés sont chacun équipés d'un calculateur qui effectue le suivi des objets détectés dans leur champ de perception et fournit la liste des pistes locales obtenues. Le rôle du Système de Perception est de fusionner les données des différents capteurs. Il s'agit donc d'une fusion de données multi-capteur, multimodale, au niveau pistes. Ce type de fusion de données touche à plusieurs problématiques. Notamment, la question de l'asynchronisme des capteurs a une grande importance. En effet, la fusion de plusieurs données n'a de sens que si ces données sont relatives au même instant. Puisque les capteurs sont indépendants et ont des fréquences de fonctionnement différentes, il est nécessaire de définir une stratégie adéquate. Contrairement au cas de fusion d'*observations*¹ où les erreurs de mesures sont considérées comme indépendantes entre elles (car elles sont affectées par un bruit supposé blanc), les erreurs d'estimation de pistes peuvent

1. Une observation est relative à un instant bien précis et correspond à une mesure non filtrée, contrairement à une piste qui est le résultat d'un filtrage des mesures au cours du temps.




Figure 2.4: Exemple de système de perception multi-capteur, multimodal

tout à fait être corrélées entre elles. En effet, le filtrage “colore” l’erreur d’estimation, selon le modèle d’évolution choisi, ce qui ne garantit plus une indépendance des erreurs d’estimation des pistes même si elles proviennent de capteurs différents. Cette corrélation est d’autant plus forte que les modèles utilisés par les capteurs se ressemblent. De ce fait, l’application des méthodes classiques de fusion de données, supposant l’indépendance des erreurs de mesures, demande une adaptation préalable. En effet, la prise en compte de l’inter-covariance est nécessaire pour éviter la sur-confiance du résultat. D’autre part, puisque les capteurs sont susceptibles de produire des pistes fantômes et d’avoir des non-détections, un module de gestion de la confiance en l’existence des pistes globales a été développé pour assurer l’intégrité du système par rapport à scène réelle. Le module de suivi d’objets est vu en détails dans le chapitre 3.

En plus du suivi d’objets, le Système de Perception fournit des informations sur la géométrie de la route. Il s’agit d’informations nécessaires à la représentation des limites des voies de la route et des courbes qu’elles dessinent. Dans cette thèse, il est admis que des données assez élaborées sur la géométrie de la route sont fournies par une caméra et son calculateur. La modélisation de la route est abordée plus en détails dans la section 4.3.

2.2.4 Module d’analyse de scène

Le module d’analyse et d’interprétation de scène se sert du résultat de la perception dynamique de l’environnement pour continuellement évaluer le risque de collision encouru par l’égo-véhicule. Les méthodes d’évaluation du risque de collision sont généralement relatives à une estimation du temps-avant-collision ou de paramètres qui en sont directement dérivés car ce temps détermine le temps de réaction disponible

pour effectuer une manœuvre d'évitement de la collision annoncée. Plus ce temps est petit, plus le risque est élevé. Son calcul nécessite de déterminer la future trajectoire de chaque objet mobile (y compris l'égo-véhicule) afin de détecter d'éventuels points communs, synonymes de collisions. La prédiction de trajectoire est l'une des tâches majeures effectuées par le MAS. La trajectoire d'un véhicule dépend, rigoureusement parlant, de très nombreux paramètres dont certains sont non mesurables ou non mesurés, comme l'intention du conducteur, son style de conduite, la friction des pneumatiques sur la chaussée etc. Prédire cette trajectoire peut donc être une tâche particulièrement ardue et sûrement non déterministe. Il est cependant possible de l'approximer en faisant des hypothèses sur le mouvement du véhicule ou en admettant des comportements nominaux qui permettent de reconnaître une manœuvre particulière, le plus tôt possible, afin de "deviner" la suite de la manœuvre.

Quelle que soit la méthode choisie, la prédiction de trajectoire est basée sur des estimations entachées d'incertitudes ; la trajectoire obtenue est donc aussi sujette à une certaine variance. Par conséquent, une collision prévue n'est pas un paramètre déterministe mais est considérée comme une variable stochastique ayant une probabilité. On parle alors de risque de collision ou de probabilité de collision. Pour déterminer cette probabilité, il est nécessaire d'estimer la variance en chaque pose sur toute trajectoire prédite.

Les méthodes de prédiction de trajectoire et de calcul de risque de collision sont discutées dans le chapitre 4.

2.2.5 Module de décision

Lorsqu'une collision s'annonce imminente, avec une probabilité assez élevée, le système doit proposer une trajectoire d'évitement de collision qui tient compte de la configuration de la scène afin d'éviter toute autre collision pendant la manœuvre. Dans l'optique ADAS, le rôle du système est d'alerter le conducteur, suffisamment tôt, en cas de danger afin qu'il réagisse lui-même. Le système n'est sensé intervenir qu'en dernier recours lorsque le temps disponible ne permet pas de pouvoir éviter la collision plus tard. La trajectoire que nous cherchons à calculer correspond à ce cas extrême, en incluant tout de même une marge de sécurité. Il faut donc déterminer la trajectoire d'évitement de collision et le temps de réaction associé, qui définit le moment où la manœuvre doit commencer. La trajectoire obtenue dépend précisément de la configuration de la scène mais on peut considérer qu'il existe un nombre limité de manœuvre d'évitement de collision. En général, il s'agit du freiner avant d'atteindre l'obstacle ou d'effectuer un écart latéral pour le contourner. On peut sans doute imaginer d'autres scénarios, mais dans cette thèse les considérations se sont limitées à ces deux cas. Le choix final se fait en fonction du temps de réaction disponible pour chaque cas de manœuvre.

Nos travaux sur le MD sont brièvement détaillés dans les perspectives de cette thèse (section 5.2) car ils sont encore en cours et n'ont pas encore faits l'objet résultats

validés.

2.3 Repère de travail

Aussi bien pour le suivi des objets détectés, que pour les prédictions de trajectoire et le calcul d'une trajectoire d'évitement de collision, le modèle de représentation des objets et les modèles d'équations décrivant leurs mouvements (modèles cinématiques) sont des aspects fondamentaux. Le modèle cinématique dépend directement du repère de travail choisi. Dans la littérature, deux grandes approches font l'objet de débats : l'approche "halo-centrée" qui considère un repère fixe par rapport au sol et l'approche "ego-centrée" qui considère un repère mobile, rigidement lié à l'égo-véhicule.

Dans cette section, nous allons donc débattre du choix du repère. Avant d'argumenter notre choix, nous allons d'abord considérer le modèle de représentation des objets.

2.3.1 Modèles de représentation d'objet

Le choix des paramètres décrivant l'état d'un objet dépend de la dynamique de l'objet et des besoins du système mais est également contraint par les capacités de mesure des capteurs utilisés. Dans la littérature, on rencontre plusieurs modèles correspondant à des situations spécifiques. Pour une fonction d'évitement de collision, le suivi des objets avec des coordonnées en deux dimensions est généralement suffisant. En effet, les objets les plus critiques en ce sens sont ceux qui sont les plus proches de l'égo-véhicule et on suppose que la route est localement plane tout autour de lui. On admet également qu'il n'y a pas d'objets volants ni d'objets plus bas que le niveau du sol. D'autre part, les mesures disponibles pour un objet dépendent des capteurs l'ayant détecté ; dans un contexte multi-capteur, multimodal, ces données peuvent donc être enrichies tout au long du processus de suivi de l'objet, grâce aux informations fournies par de nouveaux capteurs qui le détectent.

Compte tenu des capteurs utilisés, nous avons utilisé deux modèles de représentation et mis en place un mécanisme permettant de passer d'un modèle à l'autre suivant les informations disponibles et suivant les besoins. Plaçons nous dans un repère cartésien pour présenter simplement ces modèles.

Modèle d'évolution ponctuel Il est souvent utilisé lorsqu'on connaît assez mal la dynamique de l'objet ou s'il est complètement holonome (par exemple un piéton). La figure 2.5 décrit les paramètres utilisés : position (x, y) , vecteur vitesse (\vec{v}) et vecteur accélération (\vec{a}) suivant chaque dimension du repère considéré qu'il soit fixe ou mobile.

$$X = [x, y, v_x, v_y, a_x, a_y]^T$$




Figure 2.5: Modèle ponctuel d'objet

Modèle d'évolution de type char ou unicycle Il permet d'exprimer le fait qu'un mobile à roue subit souvent une contrainte odométrique, c'est-à-dire que son vecteur vitesse est parallèle à son axe longitudinal. Il est défini en fonction de la position, du lacet, de la vitesse linéaire, de l'accélération tangentielle et de la vitesse de lacet :

$$X = [x, y, \theta, v, a_T, \omega]^T$$




Figure 2.6: Modèle char, très utilisé pour les véhicules

Dans la suite du mémoire, lorsqu'il n'y a pas d'ambiguïté entre la norme du vecteur accélération et l'accélération tangentielle, cette dernière sera simplement notée a (et non a_T comme ici) pour simplifier les notations.

Passage d'un modèle à l'autre

Dans la pratique, on est souvent amené à passer d'un modèle à l'autre. Nous présentons ci-après les équations fondamentales sans prendre en compte les bruits.

Les équations suivantes permettent de passer du modèle char au modèle ponctuel ($[v, \theta, a_T, \omega] \rightarrow [v_x, v_y, a_x, a_y]$)

$$\begin{cases} v_x &= v \cos \theta \\ v_y &= v \sin \theta \\ a_x &= \sqrt{a_T^2 + v^2 \omega^2} \cos \theta \\ a_y &= \sqrt{a_T^2 + v^2 \omega^2} \sin \theta \end{cases}$$

où le produit $v\omega$ n'est autre que la norme de l'accélération normale.

Pour le passage inverse ($[v_x, v_y, a_x, a_y] \rightarrow [v, \theta, a_T, \omega]$), le lacet est calculé par la formule suivante si v_x est non nulle.

$$\theta = \arctan\left(\frac{v_y}{v_x}\right)$$

Si v_x est nulle, $\theta = \pm\pi/2$. La vitesse de lacet ω ne peut être obtenue qu'en dérivant le lacet en fonction du temps. Puis l'accélération tangentielle est obtenue par

$$a_T = \sqrt{a_x^2 + a_y^2 - v^2 \omega^2}$$


Paramètres non cinématiques

Outre les données de nature cinématique, certains capteurs sont capables de mesurer la largeur et la longueur des objets; on parle alors de modèle en boîte. De même, des données de nature sémantique comme le type des objets (véhicule, deux-roues, piéton) peuvent être obtenues. L'objectif du Système de Perception est d'obtenir le modèle le plus complet possible pour chaque objet suivi, notamment le modèle char, avec en plus les dimensions et le type de l'objet.


2.3.2 Impact du repère de travail sur le modèle d'évolution

Le référentiel de travail considéré est crucial au niveau de toutes les composantes du système global. Au niveau du Système de Perception par exemple, la localisation et le suivi des objets doit se faire par rapport à un référentiel donné. Remarquons que les mesures de chaque capteur sont fournies dans un repère mobile lié à l'égo-véhicule. Il paraît donc, a priori, plus direct d'effectuer le suivi d'objets dans un repère égo-centré. Voyons les équations à utiliser dans ce cas.

Considérons un objet cible vu de l'égo-véhicule et ayant un mouvement linéaire à accélération constante par rapport au sol. Le mouvement de cet objet n'est pas perçu de la même manière selon le repère dans lequel on se situe (voir figure 2.7).



(a) Perception dans un repère halo-centré



(b) Perception dans un repère égo-centré

Figure 2.7: Perception du mouvement d'un véhicule cible se déplaçant en ligne droite lors d'un dépassement par l'égo-véhicule.

Le mouvement linéaire dans le repère fixe (noté \mathcal{F} sur la figure) ne l'est plus dans le repère mobile (noté \mathcal{M}); son expression dépend du mouvement propre de l'égo-véhicule. Supposons que ce dernier ait, par rapport au sol, un mouvement à accélération tangentielle et vitesse de lacet constantes. Ces deux paramètres, respectivement notés a^* et ω^* ainsi que la vitesse linéaire de l'égo-véhicule notée v^* sont mesurés par des capteurs proprioceptifs. Utilisons un modèle char pour décrire le mouvement de l'objet dans le repère égo-centré.

Les équations de prédiction, en temps discret, de l'état ${}^M X_{k+1}$ de l'objet pour l'instant t_{k+1} à partir de son état ${}^M X_k$ à l'instant t_k sont données par

$${}^M X_{k+1} = \begin{cases} x_{k+1} &= \left(x_k + v_{x,k} T_e + \frac{1}{2} a_{x,k} T_e^2 \right) \cos \tilde{\theta} + \\ & \left(y_k + v_{y,k} T_e + \frac{1}{2} a_{y,k} T_e^2 \right) \sin \tilde{\theta} - \frac{a^*}{\omega^{*2}} \\ y_{k+1} &= - \left(x_k + v_{x,k} T_e + \frac{1}{2} a_{x,k} T_e^2 \right) \sin \tilde{\theta} + \\ & \left(y_k + v_{y,k} T_e + \frac{1}{2} a_{y,k} T_e^2 \right) \cos \tilde{\theta} + \frac{v^* + a^* T_e}{\omega^*} \\ v_{x,k+1} &= (v_{x,k} + a_{x,k} T_e) \cos \tilde{\theta} + (v_{y,k} + a_{y,k} T_e) \sin \tilde{\theta} - \sqrt{\tilde{v}_x^2 + \tilde{v}_y^2} \\ v_{y,k+1} &= - (v_{x,k} + a_{x,k} T_e) \sin \tilde{\theta} + (v_{y,k} + a_{y,k} T_e) \cos \tilde{\theta} \\ a_{x,k+1} &= a_{x,k} \cos \tilde{\theta} + a_{y,k} \sin \tilde{\theta} - \sqrt{\tilde{a}_x^2 + \tilde{a}_y^2} \\ a_{y,k+1} &= -a_{x,k} \sin \tilde{\theta} + a_{y,k} \cos \tilde{\theta} \end{cases} \quad (2.1)$$

avec $\omega^* \neq 0$ et

$$\begin{cases} T_e &= t_{k+1} - t_k \\ \tilde{\theta} &= \omega^* T_e \\ \tilde{v}_x &= (v^* + a^* T_e) \cos(\omega^* T_e) - v^* \\ \tilde{v}_y &= (v^* + a^* T_e) \sin(\omega^* T_e) \\ \tilde{a}_x &= -(v^* + a^* T_e) \omega^* \sin(\omega^* T_e) + a^* \cos(\omega^* T_e) - a^* \\ \tilde{a}_y &= (v^* + a^* T_e) \omega^* \cos(\omega^* T_e) + a^* \sin(\omega^* T_e) - v^* \omega^* \end{cases}$$

Les paramètres auxiliaires (notés avec un $\tilde{\cdot}$) représentent physiquement le mouvement relatif de l'égo-véhicule à l'instant t_{k+1} par rapport à l'instant t_k . La démonstration de ces équations est faite en annexe dans la section 6.4

On peut remarquer la forte non-linéarité et la lourdeur des équations obtenues malgré le fait que le modèle de mouvement de l'objet cible soit assez simple.

En exprimant cette fois-ci le même type de mouvement pour l'objet, mais dans un repère fixe (halo-centré), il est facile de montrer que

$${}^F X_{k+1} = \begin{cases} x_{k+1} &= x_k + v_{x,k} T_e + \frac{1}{2} a_{x,k} T_e^2 \\ y_{k+1} &= y_k + v_{y,k} T_e + \frac{1}{2} a_{y,k} T_e^2 \\ v_{x,k+1} &= v_{x,k} + a_{x,k} T_e \\ v_{y,k+1} &= v_{y,k} + a_{y,k} T_e \\ a_{x,k+1} &= a_{x,k} \\ a_{y,k+1} &= a_{y,k} \end{cases} \quad (2.2)$$

Au vu des équations 2.1 et 2.2, il paraît plus opportun, en terme de linéarité et de nombre de calculs, de considérer un repère halo-centré.

Pour réduire la non-linéarité on peut faire des hypothèses simplificatrices sur le mouvement de l'égo-véhicule afin obtenir des équations moins complexes en égo-centré. Par exemple, pour $\omega^* = 0$, c'est-à-dire un mouvement linéaire de l'égo-véhicule, on obtient

$${}^M X_{k+1} = \begin{cases} x_{k+1} &= x_k + (v_{x,k} - v^*) T_e + \frac{1}{2} (a_{x,k} - a^*) T_e^2 \\ y_{k+1} &= y_k + v_{y,k} T_e + \frac{1}{2} a_{y,k} T_e^2 \\ v_{x,k+1} &= v_{x,k} + a_{x,k} T_e - a^* T_e \\ v_{y,k+1} &= v_{y,k} + a_{y,k} T_e \\ a_{x,k+1} &= a_{x,k} \\ a_{y,k+1} &= a_{y,k} \end{cases} \quad (2.3)$$

Si on compare les équations 2.2 et 6.30 on obtient des équations assez similaires mais au prix d'hypothèses très simplificatrices peu adaptées à notre problème puisqu'il faut nécessairement considérer la vitesse angulaire de l'égo-véhicule pour l'évitement de collision par contournement de l'obstacle par exemple.

Notons cependant que pour effectuer le suivi d'objets dans un repère halo-centré, il est nécessaire convertir les mesures des capteurs de leur repère égo-centré vers le repère fixe. Considérons maintenant ce problème.

2.3.3 Problème de la conversion des mesures de capteurs vers un repère fixe

Soit un repère cartésien fixe, noté $\mathcal{F} (O, {}^F\vec{i}, {}^F\vec{j})$ et un repère cartésien mobile rigidement lié à l'égo-véhicule, noté $\mathcal{M} (E, {}^M\vec{i}, {}^M\vec{j})$, tels que montrés sur la figure 2.8. Le point E représente la position de l'égo-véhicule dans le repère \mathcal{F} . L'accélération tangentielle et la vitesse de lacet de l'égo-véhicule, respectivement notés a^* et ω^* sont supposés constants et sont mesurés par des capteurs proprioceptifs. Sa vitesse linéaire notée v^* est aussi mesurée.




Figure 2.8: Conversion d'état entre repère fixe et repère mobile

L'objectif est de déterminer, de façon statique, les équations de changement de repère permettant d'exprimer dans \mathcal{F} , l'état estimé ${}^M X_C$ d'une cible C par un pisteur dans \mathcal{M} . Avec

$${}^M X_C = [{}^M x_C, {}^M y_C, {}^M v_{C,x}, {}^M v_{C,y}, {}^M a_{C,x}, {}^M a_{C,y}]^T$$

Pour ce faire, il est nécessaire de connaître la position $({}^F x_E, {}^F y_E)$ du véhicule ainsi que son orientation relative (lacet) θ dans le repère \mathcal{F} . Ces paramètres sont donnés en fonction du temps par

$$\begin{cases} {}^F x_E(t) &= c_x + \frac{a^*}{\omega^{*2}} \cos(\theta_0 + \omega^* t) + \frac{v_0^* + a^* t}{\omega^*} \sin(\theta_0 + \omega^* t) \\ {}^F y_E(t) &= c_y + \frac{a^*}{\omega^{*2}} \sin(\theta_0 + \omega^* t) - \frac{v_0^* + a^* t}{\omega^*} \cos(\theta_0 + \omega^* t) \\ \theta(t) &= \theta_0 + \omega^* t \end{cases}$$

avec $\omega^* \neq 0$ et

$$\begin{cases} c_x &= x_{E,0} - \frac{v_0^*}{\omega^*} \sin(\theta_0) - \frac{a^*}{\omega^{*2}} \cos(\theta_0) \\ c_y &= y_{E,0} + \frac{v_0^*}{\omega^*} \cos(\theta_0) - \frac{a^*}{\omega^{*2}} \sin(\theta_0) \end{cases}$$

où $(x_{E,0}, y_{E,0})$ et θ_0 sont respectivement la position initiale et le lacet initial de l'égo-véhicule. Si $\omega^* = 0$, on obtient les équations suivantes

$$\begin{cases} {}^F x_E(t) &= x_{E,0} + \left(v_0^* t + \frac{1}{2} a^* t^2\right) \cos(\theta_0) \\ {}^F y_E(t) &= y_{E,0} + \left(v_0^* t + \frac{1}{2} a^* t^2\right) \sin(\theta_0) \\ \theta(t) &= \theta_0 \end{cases}$$

Ces équations sont démontrées en annexe dans la section 6.3. Par intégration en temps discret, ces équations donnent une estimation de la pose du véhicule avec des considérations purement cinématiques, sans tenir compte de toute la dynamique du véhicule et des glissements. Cela induit donc inévitablement de la dérive au bout d'un certain temps. Nous proposons, plus loin, un essai de solution à ce problème.

Notons ${}^F X_C$ l'état de l'objet cible dans le repère fixe

$${}^F X_C = \left[{}^F x_C, {}^F y_C, {}^F v_{C,x}, {}^F v_{C,y}, {}^F a_{C,x}, {}^F a_{C,y} \right]^T$$

Les équations de conversion ${}^M X_C \longrightarrow {}^F X_C$ sont données par

$${}^F X_C = \begin{cases} {}^F x_C &= {}^M x_C \cos \theta - {}^M y_C \sin \theta + {}^F x_E \\ {}^F y_C &= {}^M x_C \sin \theta + {}^M y_C \cos \theta + {}^F y_E \\ {}^F v_{x,C} &= {}^F v_{x,E} + \left({}^M v_{x,C} \cos \theta - {}^M v_{y,C} \sin \theta \right) - \omega^* \left({}^M x_C \sin \theta + {}^M y_C \cos \theta \right) \\ {}^F v_{y,C} &= {}^F v_{y,E} + \left({}^M v_{x,C} \sin \theta + {}^M v_{y,C} \cos \theta \right) + \omega^* \left({}^M x_C \cos \theta - {}^M y_C \sin \theta \right) \\ {}^F a_{x,C} &= {}^F a_{x,E} + \left({}^M a_{x,C} \cos \theta - {}^M a_{y,C} \sin \theta \right) - \\ &\quad 2\omega^* \left({}^M v_{x,C} \sin \theta + {}^M v_{y,C} \cos \theta \right) + \omega^{*2} \left({}^M y_C \sin \theta - {}^M x_C \cos \theta \right) \\ {}^F a_{y,C} &= {}^F a_{y,E} + \left({}^M a_{x,C} \sin \theta + {}^M a_{y,C} \cos \theta \right) + \\ &\quad 2\omega^* \left({}^M v_{x,C} \cos \theta - {}^M v_{y,C} \sin \theta \right) - \omega^{*2} \left({}^M x_C \sin \theta + {}^M y_C \cos \theta \right) \end{cases}$$

(2.4)

avec

$$\begin{cases} {}^F v_{x,E} &= v^* \cos \theta \\ {}^F v_{y,E} &= v^* \sin \theta \\ {}^F a_{x,E} &= a^* \cos \theta - \omega^* v^* \sin \theta \\ {}^F a_{y,E} &= a^* \sin \theta + \omega^* v^* \cos \theta \end{cases}$$

2.3.4 Choix d'une approche

Le choix du repère égo-centré ou halo-centré, au vu de la non-linéarité des équations de modèles, n'est donc pas évident car le changement de repère des mesures des capteurs vers le repère halo-centré introduit un traitement non négligeable. En considérant l'ensemble du système, le choix devient plus simple.

Au niveau du Module d'Analyse de Scène, nous montrons dans le chapitre 4 que la prédiction de trajectoire des objets suivis est fortement liée aux voies de la route. Les trajectoires sont donc d'abord prédites par rapport au sol, c'est-à-dire dans un repère fixe, indépendamment de l'égo-véhicule. Ceci donne donc une préférence au repère halo-centré. De plus les trajectoires prédites ne sont généralement pas linéaires par rapport au sol et leur conversion vers le repère mobile rajoute une forte complexité qui rend l'évaluation du risque de collision plus complexe aussi.

Au niveau du Module de Décision, les trajectoires d'évitement de collision sont liées à la configuration géométrique de la route. Pour les mêmes raisons que dans le paragraphe précédent, il nous paraît préférable de considérer un repère de travail fixe.

Les composantes principales du système global fonctionnent de façon séquentielle sans feedback entre elles. Elles sont donc fonctionnellement indépendantes ; ce qui permet d'adopter un repère de travail différent pour chacune. Toutefois, dans un souci d'harmonisation, nous avons considéré un même repère de travail, halo-centré. Rappelons que le changement de repère des mesures égo-centrées des capteurs vers le repère halo-centré considéré nécessite de connaître entre autres la position de l'égo-véhicule dans le repère fixe. Comme mentionné précédemment, l'égo-location est généralement faite en boucle ouverte par intégration de déplacements élémentaires calculés grâce aux mesures de capteurs proprioceptifs. Elle engendre souvent une dérive qui croît avec le temps. Le risque ici est donc que les erreurs de mesure initiales des capteurs combinées aux erreurs et à la dérive de l'égo-localisation donnent une erreur importante après le changement de repère. Les erreurs de mesure des capteurs sont un facteur intrinsèque qu'on ne peut éliminer mais la dérive de l'égo-localisation peut être limitée en redéfinissant périodiquement l'origine du repère fixe considéré, à la position en cours de l'égo-véhicule. La démonstration est assez simple. Ramenons nous à un problème en une dimension comme sur la figure 2.9.




Figure 2.9: Annulation de la dérive de l'égo-localisation par redéfinition de l'origine du repère fixe

Le point O est l'origine du repère fixe. Le point E symbolise l'égo-véhicule dans le repère fixe et l'origine du repère mobile. Le point C symbolise un objet cible. La position mesurée, notée ${}^F x_E(t)$ de l'égo-véhicule dans le repère fixe est obtenue en ajoutant une erreur de localisation $f(t)$ à la position vraie notée ${}^F \Delta_E(t)$:

$${}^F x_E(t) = \Delta_E(t) + f(t)$$

avec $f(t)$ une fonction croissante et $f(0) = 0$ (la dérive est nulle au départ). La position mesurée de la cible dans le repère mobile est

$${}^M x_C(t) = \Delta_C(t) + g(t)$$

où Δ_C est la vraie position et $g(t)$ est un bruit blanc symbolisant l'erreur de mesure. La position de la cible dans le repère fixe est

$${}^F x_C(t) = {}^F x_E(t) + {}^M x_C(t) = \Delta_E(t) + \Delta_C(t) + f(t) + g(t)$$

La variance de l'erreur de localisation de la cible dans le repère fixe est la somme des variances de $f(t)$ et $g(t)$. En repositionnant l'origine du repère fixe en E , après une période δt , la dérive de l'égo-localisation devient $f(t - \delta t)$. Puisque f est une fonction croissante en fonction du temps, on a $f(t - \delta t) < f(t)$.

La figure 2.10 illustre le repère de travail considéré. Il s'agit d'un repère fixe par rapport au sol mais qui est périodiquement recentré sur l'égo-véhicule afin annuler la dérive accumulée pour l'égo-localisation.

Cette technique de recadrage résout d'autre part le problème évident de dépassement de mémoire qu'on finirait par avoir à cause des valeurs extrêmement grandes des paramètres de position par exemple.

Après le choix du repère de travail qui définit en partie le contexte de l'étude scientifique dans la suite du mémoire, présentons maintenant les moyens qui nous ont permis d'évaluer les approches développées.




Figure 2.10: Le repère de travail est fixe, mais son origine est redéfini périodiquement à la position de l'égo-véhicule afin d'annuler la dérive d'égo-localisation accumulée.

2.4 Moyens d'évaluation des approches

2.4.1 Plateforme expérimentale


Le véhicule expérimental utilisé est une Peugeot 407SW équipée de plusieurs capteurs dont 5 ont été utilisés pour la perception de l'environnement. Les capteurs ont chacun un calculateur dédié (ECU¹) qui effectue un suivi d'objets local et fournit la liste des pistes locales du capteur. Un radar longue portée, une caméra monovision et un lidar 4-couches multi-écho sont utilisés pour la perception dans le secteur avant du véhicule tandis qu'un autre radar longue portée et une paire de radars moyenne portée sont montés en perception arrière. Les deux de radars deux radars moyenne portée ont le même ECU et sont, en fait, perçus comme un seul capteur. La figure 2.11 montre le montage des capteurs sur le véhicule.

Les caractéristiques techniques des capteurs sont les suivantes (les valeurs sont approximatives) :

1. Electronic Control Unit



(a)



(b)

Figure 2.11: Schéma de montage des capteurs sur le véhicule expérimental. (a) Peugeot 407 SW. (b) Vue approximative des champs de perception des capteur

Radar longue portée en perception avant

Fréquence d'ondes	76 à 77 GHz
Portée	2 à 150 m
Précision (écart-type de l'erreur)	5%
Vitesse relative	-50 à 50 m/s
Précision (écart-type de l'erreur)	5%
Ouverture angulaire	
Horizontale	16°
Verticale	3°
Fréquence de fonctionnement	12.5Hz

Caméra

Portée	90m
Précision (écart-type de l'erreur)	0-30m : 6%, 30-60m : 7%, 60-90m : 9%
Vitesse relative	
Précision (écart-type de l'erreur)	0-30m : 6%, 30-60m : 7%, 60-90m : 9%
Ouverture angulaire	
Horizontale	38°
Fréquence de fonctionnement	10Hz

Lidar

Portée	0.3 à 100m
Précision (écart-type de l'erreur)	5cm
Vitesse relative	-250 à 250km/h
Précision (écart-type de l'erreur)	3.6km/h
Ouverture angulaire	
Horizontale	120°
Verticale	3.2°
Fréquence de fonctionnement	12.5Hz

Radar longue portée en perception arrière

Fréquence d'ondes	76 à 77GHz
Portée	1 à 150m
Précision (erreur à 3σ)	1 à 20m : 1m, 20 à 150m : 5%
Vitesse relative	-180 à 180km/h
Précision (erreur à 3σ)	0.25 km/h
Ouverture angulaire	
Horizontale	16°
Verticale	5°
Fréquence de fonctionnement	12.5Hz

Paires de radars moyenne portée

Fréquence d'ondes	24 à 24.25GHz
Portée	50m
Précision (écart-type de l'erreur)	2%
Vitesse relative	-70 à 70m/s
Précision (écart-type de l'erreur)	0.14m/s
Ouverture angulaire	
Horizontale	140°
Verticale	13°
Fréquence de fonctionnement	15Hz

Comme mentionné précédemment, les capteurs émettent leurs données sur les bus CAN du véhicule. Grâce à un PC, aussi connecté aux bus CAN, et un driver que nous avons développé en langage C, le programme peut récupérer toutes les données et les traiter en temps-réel. Il s'agit d'un PC standard avec un processeur Intel(R) Core(TM) i7, 2.67GHz et avec 4Go de mémoire RAM. L'application a été développée à la fois en C++ et Matlab. Elle dispose d'une interface de visualisation interactive où sont dessinées les données des capteurs et les résultats des algorithmes développés. Grâce à l'application Canalyzer développée par la société Vector, il est possible de faire un monitoring très détaillé des communications CAN et de sauvegarder les trames utiles, par ordre chronologique, dans un fichier au format texte ou un fichier *.mat*. Ainsi, nous avons également la possibilité de rejouer les scénarios enregistrés en temps-réel sur table.

2.4.2 Simulateur de données de conduite automobile

Nous avons développé un simulateur de données qui a été utilisé pour évaluer plusieurs approches. Il se compose de deux parties principales : un générateur de scénarios de roulage et un générateur de données de capteurs. Le générateur de scénarios permet de générer des scénarios sur mesure, permettant d'outrepasser la limitation du nombre de véhicules disponibles ou encore d'avoir des scénarios de collision sans prendre aucun risque. Le générateur de données capteurs permet, lui, de simuler un nombre quelconque de capteurs et de varier leur précision. Le simulateur a été développé sous Matlab et est conçu pour s'adapter à nos besoins.

Générateur de scénarios

Le générateur de scénarios a pour but de fournir les données servant de vérité terrain par rapport à un scénario explicitement défini par l'utilisateur. Il s'agit des données relatives à l'état de chaque véhicule du scénario, sur toute la durée de la simulation, suivant la période d'échantillonnage définie. Il fournit également les dimensions de

chaque véhicule (paramètres non variables) et les données sur la route. La route est définie comme un agencement :

- de sections droites définies par leur longueur,
- de sections courbes définies par leur rayon de courbure constant, et leur angle d'ouverture,
- d'intersections définies par leur largeur et leur longueur,
- et de rond-points définis par leur rayon central (toujours 4 sorties).

Chacune de ces composantes est aussi définie par un point départ (bas, gauche), une largeur de voie, un nombre de voies et un angle d'orientation dans le repère cartésien considéré. Quelques fonctions de dessin permettent d'obtenir les différentes formes de base qui sont ensuite tournées et translatées selon la position souhaitée. Chaque forme a un rectangle englobant, de position connue, ce qui permet de retrouver les paramètres de la chaussée pour un point quelconque choisi sur la route ainsi définie. La figure 2.12 illustre un exemple de route simulée.




Figure 2.12: Un exemple de route simulée, avec plusieurs sections de chaussées droites, un rond point et une intersection

L'état d'un véhicule, à un instant donné, est défini dans un repère cartésien fixe par un vecteur X tel que

$$X = [x, y, \theta, v, a, \omega]^T$$

où les paramètres sont respectivement l'abscisse, l'ordonnée, l'angle de cap ou lacet, la vitesse linéaire, l'accélération tangentielle, et la vitesse de lacet. Pour générer un scénario, il faut définir, indépendamment, le mouvement de chaque véhicule sur toute la durée de simulation. Les interactions entre véhicules, comme par exemple, le dépassement d'un véhicule par un autre, s'obtiennent naturellement en gérant de façon manuelle le timing et les positions atteintes par chaque véhicule. Ce réglage

manuel est la partie qui demande le plus de temps, sans pour autant être une opération complexe. En effet, nous avons d'abord défini deux fonctions qui servent à créer des mouvements de base :

- La fonction *Continuer*. Elle existe en deux versions et prend en argument l'état courant du véhicule et, suivant la version, la durée ou la distance parcourue. Elle suppose que le véhicule a une vitesse de lacet et une accélération tangentielle constantes (possiblement nulles). A partir des équations analytiques décrivant un tel mouvement (voir annexe 6.3), nous obtenons l'état du véhicule pour chaque pas de temps, jusqu'à couvrir la durée/distance définie en argument. Pour simuler le mouvement d'un véhicule se déplaçant à vitesse constante v dans une voie de rayon de courbure R , il suffit de définir un point de départ à l'intérieur de la voie, un lacet θ initial égal à l'orientation de la tangente de la voie en ce point et une vitesse de lacet $\omega = v/R$. Cette fonction permet à elle seule de simuler le mouvement du véhicule dans un virage ou dans un rond-point. Pour changer le type de mouvement, il faut redéfinir manuellement la vitesse de lacet et l'accélération tangentielle qui ont donc par moment une variation instantanée, pas très naturelle.
- La fonction *ChangerVoie*. Elle permet de simuler un changement de voie. Pour ce faire, on considère d'abord que la section de route sur laquelle a lieu la manœuvre est rectiligne. La fonction prend un argument l'état courant du véhicule ainsi que l'écart longitudinal dx et l'écart latéral dy entre le point départ et le point d'arrivée de la manœuvre. On suppose ensuite que la courbe tracée par la trajectoire du véhicule respecte une fonction polynomiale de degré 3 telles que

$$y = c_3x^3 + c_2x^2 + c_1x + c_0$$

avec $c_j|_{j=0..3}$ des coefficients constants à déterminer. En notant (x_i, y_i) la position initiale du véhicule, θ_i son orientation initiale, relative à l'orientation de la tangente de la voie en ce point, et en fixant son lacet final à zéro, on peut écrire le système d'équations suivant :

$$\begin{cases} y_i & = c_3x_i^3 + c_2x_i^2 + c_1x_i + c_0 \\ y_i + dy & = c_3(x_i + dx)^3 + c_2(x_i + dx)^2 + c_1(x_i + dx) + c_0 \\ \tan \theta_i & = 3c_3x_i^2 + 2c_2x_i + c_1 \\ 0 & = 3c_3(x_i + dx)^2 + 2c_2(x_i + dx) + c_1 \end{cases}$$

En résolvant ce système nous déterminons les 4 coefficients inconnus. La courbe ainsi obtenue est ensuite déformée selon la vraie courbure de la section de route correspondante. La méthode de déformation est expliquée en annexe 6.5 et la figure 2.13 montre un exemple de déformation de trajectoire.

Nous considérons enfin que l'accélération tangentielle est constante pendant le changement voie pour obtenir la distance parcourue et la vitesse atteinte au bout de chaque période d'échantillonnage ainsi que le point correspondant sur la courbe déformée. Pour simuler un changement de voie brutal, il faut définir un dx petit.




Figure 2.13: Exemple de trajectoire de changement de voie déformée suivant la courbure de la voie. En haut, la trajectoire obtenue en supposant que la route est rectiligne et en bas, le résultat de la déformation pour un rayon de courbure égal à 150m

La grandeur de dy dépend de la largeur de la voie et son signe dépend de la direction du changement de voie (vers la voie de gauche ou de droite). Le lacet et la vitesse de lacet sont post-calculés à partir des positions successives obtenues. La fonction retourne également la durée de la manœuvre simulée.

Avec ces deux fonctions élémentaires, il est possible de définir une série de manœuvres plus complexes pour un véhicule, en partant de son état initial défini arbitrairement. En définissant les mouvements de plusieurs véhicules, on peut ainsi obtenir des scénarios plus ou moins élaborés suivant les besoins.

Générateur de données de capteurs

Avec le simulateur, il est aussi possible de simuler les données de plusieurs capteurs à partir de la vérité terrain et des caractéristiques définies pour chaque capteur. Nous rappelons que dans notre cas, les capteurs sont des capteurs-pisteurs qui effectuent un suivi d'objet local et fournissent la liste des pistes obtenues. Il faut d'abord définir le véhicule considéré comme égo-véhicule puis, le principe est le même pour chaque capteur simulé. Le processus passe par les étapes suivantes :

1. Calcul de la visibilité des objets par rapport au champ de perception du capteur
2. Ajout de bruit à la vérité terrain pour simuler des mesures bruitées
3. Suivi de cibles par filtrage de Kalman, à partir des mesures bruitées

Calcul de la visibilité des objets L'utilisateur définit le champ de perception du capteur en fournissant sa portée, son ouverture angulaire et son orientation relative

par rapport à l'axe du véhicule. Le zéro du capteur est fixé au centre de l'égo-véhicule. A partir de la vérité terrain qui est définie dans un repère cartésien fixe, on peut alors déterminer à chaque pas d'échantillonnage les véhicules présents dans le champ de perception du capteur. Le simulateur ne gère pas les cas d'occultation d'un véhicule par un autre.

Ajout de bruit à la vérité terrain Le simulateur ne simule que la mesure de la position et de la vitesse relative. L'utilisateur fournit la précision du capteur telle qu'elle pourrait être définie dans la document technique d'un capteurs réel. Par exemple

Position relative	
Précision (écart-type de l'erreur)	0-30m : 6%, 30-60m : 7%, 60-90m : 9%
Vitesse relative	
Précision (écart-type de l'erreur)	0-30m : 6%, 30-60m : 7%, 60-90m : 9%

Nous choisissons ce format parce que la précision varie généralement en fonction de la distance entre le capteur et l'objet mesuré. Les mesures du capteur sont normalement faites dans un repère mobile avec l'égo-véhicule. Comme nous avons choisi d'adopter un repère de travail fixe et pour garder une simplicité des opérations, nous rajoutons du bruit aux données de référence, en respectant la précision décrite pour le capteur. Par exemple, pour un véhicule cible visible à un instant donné de la simulation, on calcule d'abord la distance entre l'égo-véhicule et la cible ainsi que les écarts relatifs x_{rel} , y_{rel} , $v_{x,rel}$ et $v_{y,rel}$ correspondant respectivement aux paramètres x , y , v_x et v_y . Les deux derniers paramètres sont les composantes du vecteur vitesse de chaque véhicule suivant les axes du repère. Ils sont calculés comme ceci :

$$\begin{cases} v_x &= v \cdot \cos \theta \\ v_y &= v \cdot \sin \theta \end{cases}$$

Ensuite, la valeur du bruit à rajouter à la valeur de vérité terrain est obtenue par l'équation 2.5 où nous avons pris l'exemple du paramètre x .

$$x_{noise} = x_{std} \cdot randn() \quad (2.5)$$

avec

$$x_{std} = x_{rel} \cdot \frac{c}{100} \quad (2.6)$$

où x_{noise} est le bruit aléatoire rajouté et c est la valeur en pourcentage définie en paramètre pour l'écart-type de l'erreur de mesure en fonction de la distance relative.

$randn()$ est la fonction, sous Matlab, permettant de générer une valeur aléatoire en suivant une distribution gaussienne de moyenne nulle et d'écart-type 1. Nous considérons que la précision est la même suivant les deux axes du repère.

Suivi de cibles par filtrage de Kalman Enfin, un processus de suivi multi-objets, mono-capteur est mis en œuvre en utilisant les données bruitées comme mesures du capteur. Le processus est basé sur un filtre de Kalman linéaire avec un modèle de mouvement à vitesse constante. L'algorithme d'association de données utilisé est l'algorithme du plus proche voisin classique, basé sur la distance de Mahalanobis. L'écart-type des mesures correspond à x_{std} (équation 2.6) et nous avons adopté un bruit de modèle arbitraire. La sortie du processus est donc un ensemble de pistes correspondant aux véhicules simulés avec chacun leur identifiant et une estimation de leur position et de leur vitesse dans le repère fixe de simulation. Lorsque le capteur est défini très précis, les bruits générés sont faibles et les estimations des paramètres mesurés peuvent être assez correctes. Inversement, si le capteur simulé est peu précis, les estimations sont mauvaises et le suivi d'objets peut être très erroné. Dans tous les cas, l'objectif ici n'est pas d'effectuer un filtrage parfait qui rend, en sortie, la vérité terrain simulée mais de reproduire les erreurs probables du capteur simulé. Notamment, le manque de précision, les permutations d'identifiants, les pertes de cibles, etc.

2.5 Conclusion

Dans ce chapitre, nous avons présenté le système d'aide à la conduite dans sa globalité en présentant chaque composante principale ainsi que leurs fonctionnements respectifs de façon macroscopique. Le Système de Perception permet d'obtenir une représentation en temps-réel de l'environnement dans lequel évolue l'égo-véhicule. Le Module d'Analyse de Scène analyse cet environnement afin d'évaluer le risque de collision vis-à-vis des objets pertinents. Enfin, le Module de Décision détermine une trajectoire d'évitement de collision lorsque le risque de collision est important. Les flux de données entre les entrées du système et ses sorties ont été expliqués et nous avons vu les interactions entre les 3 composantes principales. Dans les chapitres suivants, nous allons aborder plusieurs problématiques liées aux tâches de chaque composante. La question du repère de travail, qui concerne la plupart de ces tâches a été abordée en détails. En effet, le choix d'un repère de travail égo-centré ou halo-centré est une question qui mérite débat en ce qui concerne le suivi d'objets car les deux approches ont chacune des avantages et des inconvénients notables. Finalement, la décision s'est portée sur un repère halo-centré au vu des considérations imposées par les Modules d'Analyse de Scène et de Décision. Dans la suite de ce mémoire, les différentes approches choisies pour répondre aux diverses problématiques abordées vont être évaluées et les résultats seront analysés. Pour ce faire, nous

avons utiliser des outils d'expérimentation qui ont été décrits. Notamment, un véhicule expérimental équipé d'équipements perception, d'une chaîne d'acquisition de données et de moyens calculs et un simulateur de données qui permet de s'affranchir de certaines limitations matérielles.

Chapitre 3

Fusion de pistes de capteurs de modalités différentes

3.1 Introduction

Le suivi d'objets consiste à identifier au cours du temps, les objets détectés, tout en maintenant à jour leurs états respectifs. A chaque objet suivi correspond une piste. L'état d'une piste est un vecteur contenant une estimation des valeurs d'un ensemble de paramètres utiles comme la position de l'objet, sa vitesse, son accélération etc. L'opération est basée sur l'utilisation d'un ou de plusieurs capteurs qui détectent les objets dans leur champ de perception et mesurent certains paramètres, suivant leur principe de fonctionnement. Le suivi d'objets est dit multimodal si les capteurs sont de types différents (radar, caméra, lidar, etc.). Les mesures obtenues d'un capteur sont généralement biaisées, imprécises et incomplètes par rapport à la réalité. Il est nécessaire d'exprimer cette incertitude en déterminant la matrice de covariance d'erreur d'estimation de l'état de la piste. La fusion de données consiste à combiner les données de plusieurs capteurs pour obtenir un résultat potentiellement plus juste, plus certain et plus complet. Les capteurs automobiles récents sont souvent équipés d'un calculateur qui effectue un suivi de cible (mono-capteur) dans leur champ de perception. Les données reçues des capteurs sont alors déjà des pistes et il s'agit de fusionner ces *pistes locales* pour obtenir les *pistes globales* du système. Les avantages à utiliser plusieurs capteurs sont nombreux. Notamment, le champ de perception global est potentiellement plus large, ce qui permet de faire une détection plus tôt des objets. La redondance de capteurs permet d'obtenir des informations plus précises et plus fiables. La variété des principes de mesures des capteurs donne la possibilité d'obtenir des informations complémentaires sur les objets. Les capteurs ont parfois des non-détections ou au contraire, détectent des objets fantômes; la fusion de données permet également d'identifier ces cas, respectivement appelés, faux négatifs et faux positifs.

Toutefois, la fusion de pistes multi-capteur multimodale soulève aussi de nombreux problèmes à résoudre. D'un point de vue pratique d'abord, les capteurs fonctionnent de façon indépendante et ont leur propre repère de mesure; il faut alors opérer un

alignement temporel et un alignement spatial de leur données avant de les fusionner. Ils ont également des fréquences d'échantillonnage différentes et leur données sont reçues de façon asynchrone. La gestion de l'asynchronisme des capteurs est une tâche cruciale car l'étape d'association de données, par exemple, requiert que les données associées soient parfaitement synchrones afin que la fusion conserve sa cohérence temporelle. Dans une application multi-capteur, le choix de l'architecture générale de traitement des données peut influencer sur les résultats. Une discussion sur ce sujet est proposée dans [Liggins et al., 2008b, Blackman and Popoli., 1999c]. On distingue principalement les architectures distribuée, centralisée et hybride. Dans le contexte de cette thèse, tous les capteurs utilisés disposent d'un module de traitement qui effectue un suivi d'objets local. Les pistes locales sont ensuite fusionnées pour obtenir des pistes globales. Il s'agit alors d'une architecture distribuée, avec une gestion centralisée des pistes globales (figure 3.1). L'étape d'association de pistes sert à déterminer les pistes locales qui seront utilisées pour mettre à jour l'état de chaque piste globale. Les erreurs d'association peuvent causer des conséquences très néfastes car cette étape prédétermine la précision et l'intégrité du résultat final par rapport à la réalité de la scène observée. La connaissance des états passés des pistes locales représente un avantage exploitable pour minimiser le nombre d'erreurs association. Dans un processus de fusion haut niveau (fusion de pistes), les pistes locales fusionnées sont issues de filtres différents mais qui pistent les mêmes objets, dans les zones de redondance. Dans [Bar-Shalom, 1981] il est démontré que dans ces conditions, il peut exister une corrélation entre les données des filtres. Lors de la mise à jour des pistes globales, il faut tenir compte de cette corrélation car les ignorer suppose une indépendance des données, ce qui conduit à un résultat sur-confiant. Afin que les faux positifs et faux négatifs des capteurs aient peu voire pas d'impact sur le résultat global, il est nécessaire, outre la gestion de la précision des données, de mettre un point un mécanisme qui gère le niveau de confiance en l'existence de chaque piste globale.

Ce chapitre présente plus en détails les problématiques citées dans le paragraphe précédent. Nous rapportons des solutions trouvées dans la littérature ainsi que celles que nous avons proposées.

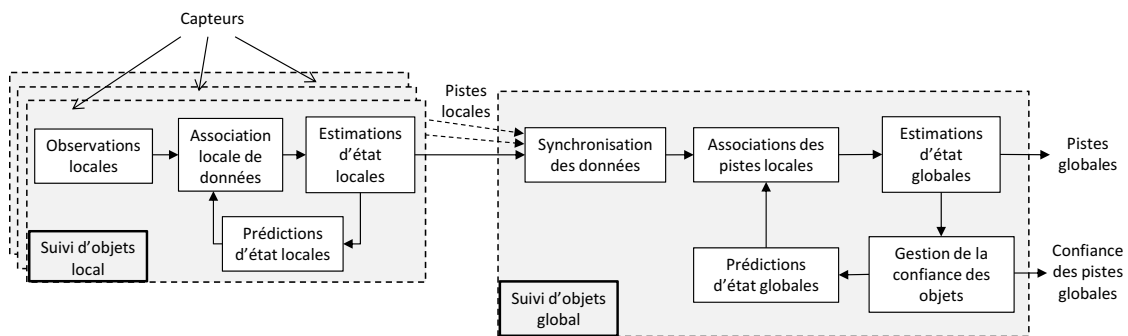


Figure 3.1: Architecture de fusion de données niveau piste

3.2 Alignement des données des capteurs

3.2.1 Alignement spatial

Les données de nature cinématique fournies par un capteur sont définies dans son propre repère local de mesure. Ce repère est généralement un repère cartésien ou un repère polaire, en deux dimensions, mobile avec l'égo-véhicule. Afin d'effectuer le suivi d'objets dans un repère de travail unique, halo-centré, il est nécessaire de convertir les mesures des capteurs vers le référentiel fixe défini. Soit ${}^M X_C$ l'estimation d'état d'une piste, faite par un capteur. Les équations de conversion pour obtenir son état ${}^F X_C$ dans le repère fixe défini ont été montrées dans la section 2.3.3. La démonstration des équations est faite en annexe dans la section 6.2.2 (page 142).

En plus de convertir l'état de l'objet, il faut convertir sa matrice de covariance d'erreur d'estimation. Soit ${}^M P_C$ la matrice de covariance dans le repère capteur et ${}^F P_C$ son équivalent dans le repère de travail. Notons $g({}^M X)$ la transformation de passage de ${}^M X_C$ à ${}^F X_C$ telle que

$${}^F X_C = g({}^M X_C)$$

La matrice de covariance dans le repère fixe s'obtient comme suit, en utilisant la dérivée de la transformation et en supposant les erreurs petites par rapport à la non linéarité.

$${}^F P_C = \left[\frac{\partial g}{\partial {}^M X}({}^M X_C) \right] \cdot {}^M P_C \cdot \left[\frac{\partial g}{\partial {}^M X}({}^M X_C) \right]^T \quad (3.1)$$

Le calcul de la jacobienne $\frac{\partial g}{\partial {}^M X}$ se fait en considérant tous les paramètres de l'égo-véhicule comme des constantes.

3.2.2 Alignement temporel

Les données fournies par chaque capteur sont datées dans une base de temps dont l'origine correspond à l'instant de démarrage de l'horloge du capteur concerné. Chaque capteur a donc une base de temps différente. Les dates de mesures fournies sont internes à chaque capteur et n'incluent pas les délais éventuels de communication avec d'autres appareils. L'alignement temporel a pour but de ramener la datation des données des capteurs à une même base de temps. Même si les capteurs sont mis sous tension au même instant, il existe toujours un décalage de leurs horloges internes pour diverses raisons matérielles qui ne sont pas discutées dans ce mémoire. De plus, en considérant un évènement se produisant à un instant donné

dans la réalité, sa détection par un capteur se fera systématiquement avec un certain retard correspondant au temps d'acquisition puis de conversion du signal physique en représentation numérique. Ce retard varie en fonction du principe de mesure du capteur. Les constantes de temps en jeu ici peuvent être très faibles, mais il est nécessaire d'en tenir compte si certains des capteurs utilisés ont des fréquences de mesure particulièrement élevées par rapport à d'autres. Pour convertir toutes les datations des capteurs vers une base commune, il suffit de déterminer le décalage temporel entre un capteur, considéré comme référence, et chacun des autres capteurs. Ensuite, il faut compenser les dates de mesure de chacun des autres capteurs par leurs décalages temporels respectifs. Les explications pour la détection du décalage temporel peuvent être ramenées à un cas de deux capteurs.

Considérons donc deux capteurs C_1 et C_2 mesurant un même paramètre pour un même objet réel, sur un intervalle de temps $I = [0, t_n]$. Soient $X = \{x_t | t \in I\}$ et $Y = \{y_t | t \in I\}$ l'ensemble des mesures effectuées respectivement par C_1 et C_2 . La figure 3.2 montre un exemple de représentation des deux séries de mesures.




Figure 3.2: Représentation de deux séries de mesures en décalage temporel.

L'objectif est de déterminer le décalage temporel noté δt entre les deux signaux. La question de l'alignement temporel de deux capteurs a été abordée dans plusieurs travaux [Huber et al., 2009, Caspi and Irani, 2002, Gooding et al., 2005] concernant des domaines d'étude variés. Les solutions proposées sont toutes semblables entre elles et semblables à celle que nous avons adoptée. La méthode consiste à effectuer des décalages temporels successifs de l'une des séries et à calculer à chaque fois le degré de similitude entre les deux séries. L'opération s'apparente à une convolution. Le décalage temporel déterminé correspond alors à celui qui maximise la corrélation entre les deux séries. Suivant les cas, la méthode de calcul de la similitude est différente. Dans le cas étudié ici, le coefficient de corrélation linéaire de Bravais-Pearson est suffisant. Il est obtenu par la formule de l'équation 3.2 où \bar{x} et \bar{y} sont

respectivement les moyennes des deux séries.

$$r_{XY} = \frac{\sum_{t=0}^{t_n} (x_t - \bar{x}) \cdot (y_t - \bar{y})}{\sqrt{\sum_{t=0}^{t_n} (x_t - \bar{x})^2} \cdot \sqrt{\sum_{t=0}^{t_n} (y_t - \bar{y})^2}} \quad (3.2)$$

Puisque les capteurs n'ont pas la même fréquence d'échantillonnage, ni les mêmes instants de mesure, il faut procéder à un ré-échantillonnage de la plus petite série pour obtenir des séries de même taille. L'opération de ré-échantillonnage consiste à faire des interpolations linéaires entre deux points successifs pour obtenir des mesures aux mêmes instants que la série de plus grande taille. Si les deux séries sont identiques, le coefficient de corrélation est maximal et vaut 1. Mais ceci rarement le cas, puisque les capteurs ont non seulement un décalage temporel non nul mais ont aussi des mesures bruitées qui ne sont pas identiques. Effectuons un décalage temporel δt de l'une des séries et réécrivons le coefficient de corrélation en fonction de ce décalage

$$r_{XY}(\delta t) = \frac{\sum_{t=0}^{t_n - \delta t} (x_{t+\delta t} - \bar{x}) \cdot (y_t - \bar{y})}{\sqrt{\sum_{t=0}^{t_n - \delta t} (x_{t+\delta t} - \bar{x})^2} \cdot \sqrt{\sum_{t=0}^{t_n - \delta t} (y_t - \bar{y})^2}}$$

Le décalage temporel entre les deux capteurs est la valeur δt qui maximise le coefficient de corrélation.

$$\Delta t = \arg \max r_{XY}(\delta t)$$

La valeur maximale testée pour δt correspond au décalage maximal admissible pour ces deux capteurs. Le pas de décalage peut être choisi aussi finement que possible car la détermination du décalage temporel des capteurs n'est pas effectuée en temps-réel.

3.3 Architecture temporelle de fusion

L'architecture globale de traitement choisie (figure 3.1 page 38) implique une gestion centralisée des données des capteurs. Le module de fusion de données reçoit donc toutes les pistes locales des capteurs et ce, de façon asynchrone. Les opérations de fusion sont effectuées de façon séquentielle et les données doivent être fusionnées dans l'ordre de leur date de validité afin de ne pas créer de graves incohérences. A cause des délais variables de transfert de données entre les capteurs et le calculateur central, il arrive que ces dernières soient reçues de façon non chronologique. Lorsqu'une donnée est reçue en retard par rapport à la date de la dernière mise à jour du système, on

parle d'*out-of-sequence*. Cette question, qui a été adressée dans de nombreux travaux, est discutée en détails dans la sous-section suivante.

Outre le problème de la chronologie des données, la fusion de plusieurs données n'a de sens que si elles sont relatives au même instant. Puisque les capteurs délivrent leurs mesures à des instants différents, il est important de définir une architecture temporelle de fusion adéquate. On rencontre deux solutions principales dans la littérature : la fusion asynchrone qui consiste à faire une mise à jour globale dès que de nouvelles données sont reçues et la fusion synchrone qui consiste à opérer une synchronisation logicielle des données des capteurs avant de faire la mise à jour.

3.3.1 Cas de l'*out-of-sequence*

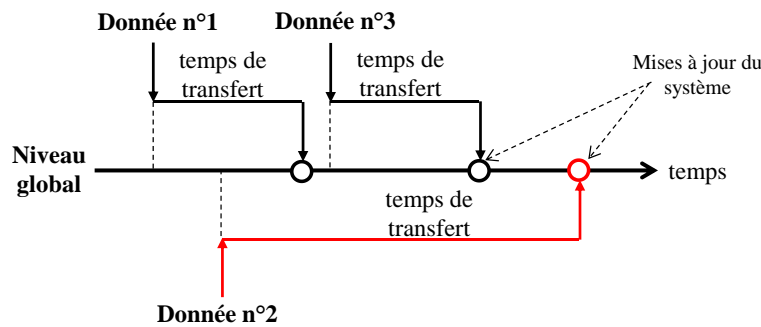


Figure 3.3: Illustration de l'*out-of-sequence*.

La figure 3.3 illustre le problème posé. La fusion de la donnée n°2 fausse la chronologie des données et peut générer de graves incohérences. Puisque les données sont datées au niveau des capteurs avant leur transfert vers le calculateur central, il est facile de détecter les cas d'*out-of-sequence* en comparant leur date à la date de la dernière mise à jour du système. Plusieurs solutions ont été proposées dans la littérature pour répondre à ce problème.

Une première méthode, simple mais sous optimale consiste à juste ignorer toute donnée reçue trop tardivement. Elle a l'avantage de conserver la cohérence temporelle de la fusion et d'être rapide (car aucun mécanisme supplémentaire n'est mis en place). Par contre, les données ignorées peuvent constituer une importante perte d'information vis-à-vis de la réalité de la scène. Toutefois, cette méthode reste acceptable dans un contexte où les temps de communication sont négligeables ou à peu près constants. En effet, dans ce cas, le nombre de cas d'*out-of-sequence* est très faible voire nul, puisque ce problème est dû à la variabilité des temps de transfert.

Une autre méthode a été mentionnée dans [Blackman and Popoli., 1999b]. Considérons qu'une donnée valide pour l'instant t_{k-1} soit finalement reçue à l'instant t_k , juste après une mise à jour globale. La méthode consiste à d'abord *rétro-prédire* les

pistes globales à l'instant t_{k-1} . Ensuite, on calcule les résidus de chaque piste globale rétro-prédite par rapport de la donnée reçue en retard. Ces résidus sont enfin utilisés pour mettre à jour les pistes globales de l'instant t_k . La méthode de calcul du gain utilisée pour la mise à jour, a été explicitée et montre que cette méthode est particulièrement gourmande en temps de calcul. Toutefois, aucune donnée n'est perdue et la fusion demeure cohérente au sens de la chronologie des données.

Dans [Kaempchen and Dietmayer, 2003] deux méthodes de tri sont proposées. Une première méthode, dite non déterministe, consiste à stocker toutes les données reçues jusqu'à réception d'au moins une donnée de chaque capteur. Elles sont ensuite triées avant d'être fusionnées. En supposant au moins que les données d'un même capteur arrivent toujours dans le bon ordre, on s'assure ainsi de toujours effectuer une fusion de données chronologiquement cohérente. L'inconvénient de cette méthode est que le système fonctionne avec un retard non négligeable par rapport à la scène perçue ; ce qui n'est pas adapté à une application temps-réel. La deuxième méthode dite déterministe suit le même raisonnement mais suppose qu'on connaît à priori le temps de transfert des données. Ainsi, les contraintes d'attente sont plus souples et le retard global du système peut être atténué.

Une autre méthode proposée par C. Tessier dans son mémoire de thèse [Tessier, 2007], consiste à garder en mémoire toutes les données reçues ainsi que l'état global du système, sur une fenêtre temporelle glissante, de taille fixe. Les données sont normalement fusionnées (quelle que soit de la méthode de fusion choisie) tant que la chronologie est respectée. Lorsqu'un cas d'*out-of-sequence* est détecté, on se sert de la sauvegarde pour "remonter le temps", jusqu'au moment de la validité de cette donnée puis on refait la fusion de données, dans le bon ordre, depuis cet instant jusqu'au présent. Cette méthode est plus gourmande en mémoire et nécessite de connaître une majoration de la latence des capteurs afin de définir la taille de la fenêtre temporelle glissante. En cas de réceptions tardives récurrentes, le système finit pas accuser du retard par rapport au temps réel.

Cette dernière méthode est celle que nous avons adoptée car elle ne fait aucune supposition forte par rapport à la réalité, sa mise en œuvre est simple et n'influe pas sur la technique de fusion de données fondamentalement choisie.

3.3.2 Fusion asynchrone de données

Cette architecture de fusion, illustrée par la figure 3.4, consiste à faire une mise à jour du système dès qu'une nouvelle donnée est reçue d'un capteur. Les informations sont donc immédiatement intégrées au niveau global dès qu'elles sont disponibles et le système a théoriquement très peu de retard vis-à-vis de la scène. D'autre part, puisque les données n'ont pas besoin d'être stockées, cette architecture est peu gourmande en mémoire. De plus, une opération de mise à jour peut être particulièrement rapide car elle n'implique que les données d'un seul capteur à la fois. Cette dernière remarque est toutefois nuancée par le fait que le nombre de mises à jour globales effectuées est plus




Figure 3.4: Fusion asynchrone. Les données sont fusionnées au fur et à mesure de leur réception.

important. Cette architecture présente aussi de nombreux inconvénients. En effet, lorsque le nombre de capteurs utilisés devient important, les réceptions de données sont très rapprochées dans le temps, voire concurrentes. Puisque la fusion doit être effectuée immédiatement dès la réception des données, ceci crée de l'instabilité au niveau algorithmique. Une solution consiste à mémoriser temporairement les données concurrentes puis à les fusionner séquentiellement, ce qui génère finalement du retard et utilise plus de mémoire. Il faut aussi remarquer que l'arrivée concurrente de données et leur fusion immédiate laissent peu de tolérance aux cas d'*out-of-sequence*. En effet, à chaque cas de réception tardive, le mécanisme de correction choisi (voir section 3.3.1) devra systématiquement être exécuté. D'autre part, les informations fournies par les capteurs ne sont jamais directement confrontées entre elles avant de faire une mise à jour globale du système ; chaque capteur met individuellement à jour l'information globale qui a plus de chance d'être momentanément "polluée" en cas de données erronées ou imprécises. Comme nous le verrons dans la suite, la comparaison directe des données des capteurs permet de confirmer ou d'infirmer instantanément certaines hypothèses avant leur intégration au niveau global.

3.3.3 Fusion synchrone de données

L'architecture de fusion synchrone, illustrée par la figure 3.5, consiste à mettre en place un mécanisme de synchronisation logicielle des données afin de permettre une mise à jour du système avec les données de tous les capteurs à la fois. Le mécanisme de synchronisation consiste à définir une période fixe de mise à jour, calée sur la période du capteur le plus rapide. La dernière donnée de chaque capteur est sauvegardée dans une mémoire dédiée qui est écrasée par une nouvelle donnée du même capteur. A chaque instant de réception de données du capteur le plus rapide, les données sauvegardées des autres capteurs sont extrapolées pour cet instant. Ainsi, des données de tous les capteurs sont disponibles, aux instants de mise à jour du système. Cette architecture a pour avantage d'être plus régulière car elle a une période fixe de mise à jour. Ce qui est très utile au regard d'une autre application cliente du résultat du suivi d'objets et procure beaucoup plus de stabilité d'un point de vue calculatoire. En cas de données concurrentes, les opérations d'extrapolation




Figure 3.5: Fusion synchrone. Synchronisation des données par extrapolation de la dernière sortie de chaque capteur. Ici l'une des sorties du Capteur 3 a été extrapolée deux fois

peuvent parfaitement se faire en parallèle, étant indépendantes. Puisqu'il y a un estimé de la scène par chaque capteur lors de la mise à jour du système, il est possible de faire une comparaison instantanée des données des capteurs redondants. Cela facilite l'étape d'association de données ainsi que la détection de pistes fantômes par exemple. Un autre avantage non négligeable est qu'il y a beaucoup de flexibilité par rapport aux cas d'*out-of-sequence*. En effet, le retard de transfert d'une donnée n'a aucun impact tant que la donnée est reçue avant la prochaine mise à jour. En cas de forte latence, il faut utiliser l'une des solutions présentées dans la section 3.3.1. Cette méthode a également ses inconvénients, comme le besoin de plus de mémoire pour stocker les données. De même, elle crée de la rétention de données entre deux mises à jour mais cet aspect est acceptable si la fréquence du capteur le plus rapide est raisonnable au vu du besoin. D'autre part, les opérations de prédictions occasionnent plus de calculs ; cela ne génère toutefois que peu de retard car ces opérations se font en parallèle. Les éventuelles erreurs de prédictions peuvent également causer de l'imprécision.

3.3.4 Choix d'une stratégie

L'architecture développée pour les expérimentations est celle de la fusion synchrone car en plus des avantages cités, elle présente d'autres atouts du point de vue globale de l'application ADAS étudiée. En effet, le suivi d'objets n'est qu'une étape de cette application ; le Module d'Analyse de Scène nécessite une estimation aussi régulière et stable que possible de l'état de la scène. De plus, la méthode de gestion des cas d'*out-of-sequence* que nous avons adoptée demande déjà une mémorisation des données des capteurs, il n'y a donc pas besoin de mémoire supplémentaire.

Pour nos expérimentations, les capteurs utilisés sont assez rapides. Leurs fréquences sont comprises entre 10Hz et 15Hz, ce qui signifie que toutes les extrapolations (prédictions d'état) sont effectuées pour une durée inférieure à 100ms. Il est alors acceptable d'adopter un modèle de mouvement linéaire à accélération constante pour les prédictions, ce qui rend le calcul assez rapide. Soit $X = [x, y, v_x, v_y, a_x, a_y]^T$ l'état

d'un véhicule défini dans un repère cartésien par sa position et sa vitesse suivant les deux axes et soit P la matrice de covariance associée. Son état X_{k+1} à un instant t_{k+1} est prédit à partir de son état X_k à l'instant t_k par la formule suivante

$$X_{k+1} = A \cdot X_k$$

où

$$A = \begin{bmatrix} 1 & 0 & T_e & 0 & \frac{1}{2}T_e^2 & 0 \\ 0 & 1 & 0 & T_e & 0 & \frac{1}{2}T_e^2 \\ 0 & 0 & 1 & 0 & T_e & 0 \\ 0 & 0 & 0 & 1 & 0 & T_e \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix}$$

avec $T_e = t_{k+1} - t_k$

La matrice de covariance est prédite comme ceci

$$P_{k+1} = A \cdot P_k \cdot A^T + Q$$

où Q est la matrice de covariance du bruit de modèle.

Pour une représentation en modèle char avec $X = [x, y, \theta, v, a, \omega]^T$, on obtient

$$X_{k+1} = f(X_k)$$

où

$$f(X_k) = \begin{bmatrix} x_k + \left(v_k T_e + \frac{1}{2} a_k T_e^2 \right) \cos \theta_k \\ y_k + \left(v_k T_e + \frac{1}{2} a_k T_e^2 \right) \sin \theta_k \\ \theta_k \\ v_k + a_k T_e \\ a_k \\ 0 \end{bmatrix}$$

La matrice de covariance est prédite par

$$P_{k+1} = J \cdot P_k \cdot J^T + Q$$

où J est la jacobienne de f en X_k :

$$J = \begin{bmatrix} 1 & 0 & -\left(\frac{1}{2}a_k T_e^2 + v_k T_e\right) \sin \theta_k & T_e \cos \theta_k & \frac{1}{2}T_e^2 \cos \theta_k & 0 \\ 0 & 1 & \left(\frac{1}{2}a_k T_e^2 + v_k T_e\right) \cos \theta_k & T_e \sin \theta_k & \frac{1}{2}T_e^2 \sin \theta_k & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & T_e & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

3.4 Association de pistes locales

Dans un cycle classique de fusion de données pour le suivi d'objets, l'étape suivant la réception de nouvelles données-capteur est l'association de données. Elle consiste à faire une correspondance entre les pistes courantes du système et les nouvelles détections. Cette association permet ensuite de mettre à jour les états des pistes du système, en se servant des données qui leur ont été respectivement associées. Cette étape est donc déterminante car une erreur d'association entraîne de graves répercussions sur la précision et l'intégrité de l'information du système par rapport à la scène réelle. Pour respecter la cohérence temporelle, l'association de données se fait plus exactement entre les nouvelles détections des capteurs et les états prédits des pistes du système pour la date des nouvelles détections.

On rencontre plusieurs méthodes d'association de données dans la littérature. Certaines approches, dites mono-hypothèses, supposent qu'à chaque détection retournée par un capteur, correspond un seul objet réel ; c'est-à-dire qu'elles cherchent à associer au plus une détection d'un même capteur à une piste du système et une même détection d'un capteur est associée à au plus une piste du système. C'est le cas de l'algorithme du plus voisin généralisé (GNN¹) [Konstantinova et al., 2003], du Fuzzy C-Mean clustering (FCM) [Bezdek et al., 1984, Aziz et al., 1999, Aziz, 2006] et de méthodes basées sur la théorie des fonctions de croyance [Mercier et al., 2011]. Cette supposition exclut donc les cas où, à cause d'une mauvaise segmentation de données par exemple, un capteur retourne plus d'une détection pour un même objet. Cette possibilité est prise en compte par d'autres méthodes dites multi-hypothèses comme l'association probabiliste jointe de données (JPDA²) [Bar-Shalom and Scheffe, 1980]. Pour un système multi-capteur, une approche mono-hypothèse signifie qu'une même piste système peut être associée à plusieurs détections mais de capteurs différents. On peut, ici, remarquer le corolaire avec les approches multi-hypothèses.

Dans le contexte de cette thèse, les données des capteurs sont des pistes, c'est-à-dire issues d'un filtrage préalable qui permet d'admettre que le nombre d'objets

1. Global Nearest Neighbor
2. Joint Probabilistic Data Association

dupliqués, au niveau d'un même capteur, est a priori faible. De ce fait, les approches mono-hypothèses sont d'autant plus légitimes.

3.4.1 Approches mono-hypothèse

En pratique, la méthode d'association de données la plus rencontrée et la plus utilisée dans les applications automobiles est l'algorithme du plus proche voisin (NN¹). Elle est souvent employée à cause de sa simplicité et de sa rapidité par rapport aux autres méthodes. Elle s'adresse par défaut à un cadre mono-capteur mais peut être étendue aux cas multi-capteurs, comme expliqué dans la suite de ce mémoire. Son principe est le suivant : considérons un ensemble de N pistes prédites du système et on veut trouver leurs correspondants parmi un ensemble de M détections du capteur. Admettons que les vecteurs d'état et les vecteurs représentant les détections sont similaires et que les erreurs du capteur sont assimilées à du bruit blanc. On calcule dans un tableau de taille $M \times N$ les distances statistiques correspondant à chaque paire piste-détection possible. La distance statistique entre une prédiction d'état de piste X_i et une détection X_j est donnée par la formule suivante :

$$d_{ij}^2 = (X_i - X_j)^T \cdot (P_i + P_j)^{-1} \cdot (X_i^{(s)} - X_j^{(c)}) \quad (3.3)$$

où P_i et P_j sont respectivement les matrices de variance de X_i et X_j .

Cette expression, qui correspond à la distance de Mahalanobis, suit une distribution du χ^2 (dont le nombre de degrés de liberté correspond à la taille du vecteur d'état). Un simple seuillage permet donc de tester l'adéquation entre X_i et X_j (test du χ^2) et de rejeter dès le départ les associations très improbables. Cette opération s'appelle le fenêtrage. En pratique, le seuil est généralement défini à $d_{max}^2 = 9$, ce qui correspond à 3 écarts-types du résidu $(X_i - X_j)$. Les pistes ayant une grande imprécision ont tendance à "absorber" des détections pourtant éloignées, à cause leur matrice de covariance plutôt large. Pour pénaliser ces cas, il est courant d'utiliser la distance statistique généralisée :

$$d_{G_{ij}}^2 = d_{ij}^2 + \ln(|P_i + P_j|)$$

où d_{ij}^2 est donnée dans l'équation équation (3.3).

En fait, minimiser $d_{G_{ij}}$ revient à maximiser la probabilité d'association sous hypothèse gaussienne, du fait que le déterminant intervient dans le terme de normalisation de la loi gaussienne. Ensuite, par une recherche itérative de la distance minimale contenue dans le tableau obtenu, les meilleures associations sont définies une par

1. Nearest Neighbor

une. Les données déjà associées sont exclues pour les itérations suivantes. Les pistes systèmes non associées correspondent à des objets qui n'ont plus été détectés et les détections non associées correspondent à de nouveaux objets de la scène.

Dans [Aziz, 2006, Aziz et al., 1999], les auteurs proposent une méthode d'association mono-hypothèse basée sur l'algorithme du FCM¹. La démarche consiste à d'abord considérer l'une des catégories de données à associer comme référence ; il peut s'agir de l'ensemble des pistes du système ou de l'ensemble des détections du capteur. Chaque élément de l'ensemble de référence est ensuite considéré comme un centre de classe, puis on calcule le degré d'appartenance de chacune des autres pistes ou détections à chaque classe ainsi définie. Le degré d'appartenance μ_{ij} d'un état X_j à une classe de centre X_i est obtenu par la formule

$$\mu_{ij} = \frac{1}{\sum_{k=1}^K \left(\frac{d_{ij}}{d_{kj}}\right)^{2/(m-1)}}$$

avec $d_{ij} = \left\|X_i^{(s)} - X_j^{(c)}\right\|^2$, K étant le nombre de classes et m , appelé "constante de floutage" est un coefficient de pondération supérieur ou égal à 1. La matrice des degrés d'appartenance est ensuite traitée comme dans le cas de l'algorithme du plus proche voisin pour définir les associations ; sauf qu'on recherche itérativement le maximum de degré d'appartenance et non la distance minimale.

Dans [Mercier et al., 2011], les auteurs proposent une méthode basée sur l'utilisation des fonctions de croyance. Considérons ici aussi un ensemble de N pistes prédites du système à associer avec un ensemble de M détections de capteur. La théorie des fonctions de croyance a été introduite par Dempster et Shafer dans [Dempster, 1968, Shafer, 1976] et est souvent considérée comme une généralisation de la théorie des probabilités afin de mieux modéliser l'ignorance. La méthode proposée consiste à d'abord associer une fonction de masse m_{ij} à chaque hypothèse d'association $X_i X_j$ possible. Cette fonction définit trois valeurs :

- $m_{ij}(\{1\})$, la masse accordée à l'acceptation de l'association (X_i, X_j)
- $m_{ij}(\{0\})$, la masse accordée au rejet de l'association (X_i, X_j)
- $m_{ij}(\{0, 1\})$, la masse accordée à l'indécision ou ignorance

Chaque masse est calculée en fonction des états des objets. Il existe plusieurs formules de calcul dont certaines sont disponibles dans [El-Zoghby et al., 2013]. Ensuite, la probabilité pignistique de chaque hypothèse d'association est calculée à partir des toutes les fonctions de masses définies. On obtient alors une matrice de taille $M \times N$ correspondant aux probabilités d'accepter chaque hypothèse d'association possible. Enfin, les associations acceptées sont définies en recherchant itérativement celle qui a la probabilité maximale.

1. Fuzzy c-Means clustering

3.4.2 Architectures d'association de données multi-capteur

Dans un contexte multi-capteur, il existe trois possibilités d'association :

1. Les pistes locales de chaque capteur sont indépendamment appariées aux prédictions d'état des pistes globales courantes du système. Cette option est la seule disponible pour une architecture de fusion asynchrone (section 3.3.2) car cette dernière impose un traitement indépendant des données de chaque capteur. Ceci revient alors à effectuer plusieurs associations de données mono-capteur (une par capteur).




Figure 3.6: Cas d'école avec 3 capteurs et deux pistes. L'association de données, matérialisée par une ellipse, se fait indépendamment entre les pistes locales de chaque capteur et les pistes globales du système.

2. Les pistes locales et les pistes globales sont toutes directement associées entre elles. Ici, il y a une seule étape d'association de pistes multi-capteur où le nombre de catégories de données à associer correspond au nombre total de capteurs considérés plus une (l'ensemble des pistes globales).




Figure 3.7: L'association de données se fait directement entre toutes les pistes locales de tous les capteurs et toutes les pistes globales du système

3. Les pistes locales sont d'abord associées entre elles sans tenir compte des pistes globales. Les pistes locales d'un même groupe sont ensuite combinées pour avoir une estimation appelée *super-observation* dans ce document. Les super-observations sont par la suite associées avec les états prédits des pistes globales courantes. Cette opération se passe donc en deux étapes : une étape d'association de pistes multi-capteur où le nombre de catégories de données à associer correspond au nombre total de capteurs considérés et une étape d'association de type mono-capteur où il y a deux catégories de données. Il faut remarquer

que les super-observations sont des estimations ponctuelles qui n'ont pas d'historique car d'une itération à l'autre, durant le processus de fusion, les pistes associées ne sont pas toujours les mêmes.




Figure 3.8: Les pistes locales des capteurs sont d'abord associées entre elles (a) pour former des super-observations qui sont ensuite associées avec les pistes globales du système (b)

L'avantage de la solution 1 est que pour chaque capteur, l'association de données demande moins de calculs qu'un cas multi-capteur. Néanmoins, l'opération est à réaliser autant de fois qu'il y a de capteurs, ce qui atténue quelque peu cet avantage. Par contre, son inconvénient par rapport aux deux autres solutions est que ces dernières, qui imposent une synchronisation des données, permettent de comparer simultanément les données des diverses sources. Cet aspect représente un avantage très important pour gérer de façon rapide la confiance en l'existence des pistes globales comme nous le verrons dans la section 3.7. Des solutions 2 et 3, nous préconisons finalement la 3 car elle présente, en plus, des avantages qui seront expliqués lors de l'étape d'estimation d'état des pistes globales (section 3.5.4).

3.4.3 Proposition d'une méthode d'association

Compte tenu du fait que les capteurs du système étudié fournissent des pistes, issues d'un filtrage de données, nous avons privilégié les approches mono-hypothèse. La faiblesse de la méthode FCM est qu'elle est basée sur la norme de l'écart entre les estimations d'états et ne tient pas compte de leurs variances ; ce qui est sous-optimal. La méthode utilisant les fonctions de croyance nécessite un important traitement préalable : pour chaque paires possibles, il faut calculer 3 fonctions de masse (association, non-association et ignorance) et calculer les probabilités pignistiques. Si le nombre de capteurs est élevé, on assiste à une explosion du nombre de calculs qui rend le traitement en temps-réel difficile. Pour pouvoir appliquer cette méthode en temps-réel, il faut que le nombre de capteurs soit très limité ; ce qui sort du contexte de notre système.

Pour ces travaux, nous avons utilisé la méthode du plus proche voisin. Sa simplicité et sa rapidité sont des atouts extrêmement importants pour une exécution en temps-réel, vu le caractère multi-capteur du système. De plus, elle permet une modification facile de l'algorithme de base pour réduire le risque de mauvaise association. La

modification proposée repose sur le principe de calcul de distance entre deux pistes en utilisant des horizons de données (section 3.4.3). Nous verrons ensuite le détail de l’algorithme du plus proche voisin étendu à N capteurs (section 3.4.3).

Calcul de la distance entre deux pistes

Dans la section 3.4.1, l’expression “détectons des capteurs” désigne indifféremment de simples observations de capteurs ou des pistes de capteurs issues d’un suivi d’objets local. Dans le contexte de cette étude, les détectons des capteurs sont des pistes locales. Contrairement à une observation qui est une mesure ponctuelle, une piste est le résultat d’un filtrage qui a une durée dans le temps et il est possible de mémoriser les états passés de la piste depuis sa création. Notons que la connaissance de l’historique des pistes peut aider à faire de meilleures associations. On peut rapidement se rendre compte de ce fait sur la figure 3.9. Elle représente trois pistes A , B et C dont l’état est réduit aux coordonnées (x, y) dans un repère cartésien, pour simplifier les explications. Les positions passées des pistes jusqu’à l’instant courant t_k sont représentées. En ne considérant que l’instant t_k , on est plus susceptible d’associer la Piste C à la Piste A plutôt que de lui associer la Piste B car la Piste C est plus proche d’elle à cet instant. Par contre, en considérant leurs historiques respectifs, il est clair qu’il faut plutôt associer la Piste B à la piste A .




Figure 3.9: Association de pistes en considérant l’historique

La plupart des méthodes d’association mono-hypothèse sont finalement basées sur un calcul de similitude deux-à-deux entre les données à associer : la distance statistique pour le NN, la norme du résidu pour le FCM, la probabilité pignistique pour les fonctions de croyance. Les erreurs d’association sont commises lorsque que la similitude évaluée ne reflète pas la réalité des faits. Ceci peut être dû à un manque de précision des capteurs, à des erreurs de prédiction de pistes globales ou bien lorsque deux objets se croisent ou restent proches temporairement. Dans ce dernier cas, leur proximité temporaire peut conduire à faire des permutations. Pour limiter ce risque,

on peut se servir de la connaissance de l'historique. En faisant une moyenne des similitudes évaluées sur les N dernières estimations d'état au lieu de ne considérer que l'instant t_k , les ambiguïtés dues à une proximité temporaire seront dissipées. En effet, les pistes qui ont toujours été proches l'une de l'autre (parce qu'elle proviennent du suivi d'un même objet) auront une forte similitude moyenne tandis que celles qui ont été plus éloignées entre temps, auront une similitude moyenne faible. Pour le cas du NN, la distance considérée pour deux pistes ($TTTD$ ¹) dont les états sont respectivement X_i et X_j est donc obtenue par l'équation

$$\bar{d}_{ij,k} = \frac{1}{N} \sum_{n=0}^{N-1} d_{ij,k-n} \quad (3.4)$$

où l'indice k désigne une valeur relative à l'instant t_k et d_{ij} est la distance statistique entre les pistes. La valeur de N doit être choisie de façon raisonnable pour limiter la quantité de mémoire nécessaire ainsi que le nombre de calculs. Cette expression ne respecte plus une loi du χ^2 mais l'effet escompté pour le fenêtrage est le même.

L'expression de d_{ij} telle que décrite dans l'équation 3.3 suppose que les erreurs d'estimation des deux pistes ne sont pas corrélées. Or, dans [Bar-Shalom, 1981] et dans la section 9.2 de [Blackman and Popoli., 1999a] il est montré qu'il peut exister une corrélation entre les erreurs d'estimation de deux pisteurs qui suivent un même objet. En effet, elle peut être due à l'utilisation d'un même bruit de modèle par exemple. D'autre part, une erreur d'estimation d'état ne peut pas être considéré comme du bruit blanc car elle dépend fortement du modèle utilisé pour l'estimation. L'expression de d_{ij} tenant compte de cette corrélation est la suivante :

$$d_{ij}^2 = (X_i - X_j)^T \cdot (P_i + P_j - P_{ij} - P_{ij}^T)^{-1} \cdot (X_i - X_j)$$

où P_i et P_j sont les matrices de covariance de X_i et X_j et P_{ij} est leur inter-covariance.

La détermination exacte de P_{ij} nécessite de connaître les caractéristiques des pisteurs considérés (modèles d'évolution, bruit de modèle, bruit de mesure). Une méthode de calcul a été expliquée dans [Bar-Shalom, 1981] pour le cas de filtres de Kalman. Dans [Bar-Shalom and Li, 1995], on retrouve une formule approximative de calcul qui peut être utilisée lorsque les caractéristiques des filtres sont inconnues :

$$P_{ij}(l, m) = \rho \sqrt{P_i(l, m) \cdot P_j(l, m)} \quad (3.5)$$

où (l, m) représente les coordonnées d'un élément de la matrice et ρ est le coefficient de corrélation. La valeur de ρ peut être estimée numériquement par simulation de Monte-Carlo. Pour un suivi d'objet 2D, $\rho \approx 0.4$ est la valeur conseillée.

1. Track-To-Track Distance

De notre cas d'étude, les capteurs sont des "boîtes noires" et nous ignorons les paramètres des filtres utilisés; nous ne pouvons donc pas déterminer les valeurs exactes des matrices d'inter-covariance et les calculs de distance sont forcément sous-optimaux.

Extension de l'algorithme du plus proche voisin

L'algorithme du plus proche voisin tel qu'expliqué dans la section 3.4.1 correspond à un cadre mono-capteur où il faut associer les prédictions d'état des pistes globales aux nouvelles détections du capteur. Comme expliqué prochainement dans la section 3.4.2, pour une application multi-capteur, l'association de données peut se faire indépendamment, capteur par capteur (ce qui correspond à plusieurs associations de données mono-capteurs) ou alors avec tous les capteurs à la fois. Dans ce dernier cas, il s'agit de former des groupes de pistes qui répondent aux deux exigences suivantes :

1. Dans chaque groupe de pistes obtenu après l'association, il y a au plus une piste de chaque capteur car on admet que chaque pisteur produit au plus une piste locale par objet réel (pas de doublon par exemple).
2. Une même piste locale en entrée de l'algorithme ne peut appartenir qu'à un et un seul groupe obtenu en sortie.

Nous proposons l'algorithme 3.1 (publié dans [Houenou et al., 2012]). Il est écrit ici en langage naturel pour en faciliter la compréhension.

Le fait de calculer au départ, toutes les distances deux-à-deux entre pistes puis de chercher itérativement la distance minimale de la matrice pour définir une nouvelle association assure que chaque nouvelle association est la meilleure possible à cette étape et que les premières associations sont meilleures que les suivantes. C'est pour cela qu'à l'étape 4.d.i, si les deux pistes ont déjà été associées à un groupe de pistes, on ne modifie rien. La valeur définie pour le seuil à l'étape 2.d dépend de la qualité des capteurs. Si les capteurs sont plutôt performants, leurs estimations pour un même objet réel seront assez proches entre elles puisqu'elles seront toutes proches de l'état réel de l'objet détecté. Dans ce cas, le seuil peut être défini aussi petit que possible pour limiter les chances d'englober la piste d'un autre objet. Par contre, si certains capteurs sont plutôt biaisés et imprécis, il peut arriver que des pistes représentant un même objet soient éloignées les unes des autres; dans ce cas, il faut élargir la fenêtre d'association. Toutefois, si la fenêtre d'association est trop grande, non seulement il peut y avoir des associations aberrantes mais la complexité de l'algorithme est plus grande car le fenêtrage sert aussi à limiter le nombre de comparaisons de distances à chaque itération. Si à l'étape 4.a il y a une multiplicité de la valeur minimale $ValMin$, chaque hypothèse, doit être évaluée et si les résultats sont différents, il faut choisir celui où la somme des distances entre pistes d'un même groupe est la plus petite.

Algorithme 3.1 Algorithme du GNN étendu à plusieurs capteurs

1. Attribuer un numéro d'ordre de 1 à N à chaque piste, N étant le nombre total de pistes.
 2. Créer une matrice de dimension $N \times N$ pour le calcul des distances deux-à-deux entre pistes
 - a) Mettre les éléments au dessus de la diagonale à une valeur maximale ($ValMax$), considérée comme infinie, pour ne pas calculer deux fois la distance entre deux mêmes pistes.
 - b) Mettre les éléments correspondant à deux pistes d'un même capteur à $ValMax$ pour ne pas associer les pistes d'un même capteur.
 - c) Pour les autres éléments, calculer la distance entre les deux pistes correspondantes.
 - d) Mettre les cases dont la valeur dépasse un seuil défini à $ValMax$. Ce seuil représente une fenêtre d'association en dehors de laquelle on admet que les deux pistes ne peuvent pas représenter le même objet réel.
 3. Initialiser une variable $ValMin$ à zéro
 4. Tant que $ValMin < ValMax$:
 - a) Déterminer la valeur minimale de la matrice et l'attribuer à $ValMin$. Sauvegarder sa position (l, m) ainsi que les capteurs C_1 et C_2 correspondant respectivement aux pistes numérotées l et m
 - b) Si aucune de ces deux pistes n'a déjà été ajoutée à un groupe
 - i. alors mettre ces deux pistes dans un nouveau groupe.
 - c) Sinon, si seulement une des pistes a déjà été ajoutée à un groupe,
 - i. alors ajouter l'autre piste à ce groupe.
 - d) Sinon (si les deux pistes avaient déjà été ajoutées à un même groupe ou à deux groupes différents)
 - i. (ne rien faire).
 - e) Fin Si
 - f) Mettre à $ValMax$ les éléments de la ligne l correspondant aux pistes du capteur C_1 ainsi que les éléments de la colonne m correspondant aux pistes du capteur C_2 . Ceci pour éviter d'ajouter plus tard d'autres pistes de ces capteurs au groupe identifié aux étapes (b) ou (c).
 5. Toutes les pistes n'ayant pas de groupe forment chacun un nouveau groupe (des singletons).
-

Exemple d'exécution de l'algorithme Considérons un cas simple avec un véhicule porteur ayant quatre capteurs et quatre véhicules présents dans la zone redondante de leurs champs de perception. La figure 3.10 montre les de détections des capteurs. Les T_{ij} sont les positions des pistes capteur à un instant t , i représente le numéro du capteur et j le numéro de la piste. Les points rouges représentent la position réelle des cibles suivies et les ellipses rouges représentent les groupes de pistes capteur issues d'une même cible. Le résultat de l'algorithme doit donc être : $\{T_{11}, T_{23}, T_{31}, T_{41}\}$, $\{T_{12}, T_{22}\}$, $\{T_{13}, T_{32}, T_{24}\}$ et $\{T_{21}\}$.

Nous montrons dans la suite, l'évolution du tableau des TTTD (distance deux-à-deux entre pistes) et les groupes obtenus au fur et à mesure du déroulement de l'algorithme à partir de l'étape 2.




Figure 3.10: Exemple d'association de pistes.

Étape 3

	T_{11}	T_{12}	T_{13}	T_{21}	T_{22}	T_{23}	T_{24}	T_{31}	T_{32}	T_{41}
T_{11}	∞	\times	\times	\times	\times	\times	\times	\times	\times	\times
T_{12}	∞	∞	\times	\times	\times	\times	\times	\times	\times	\times
T_{13}	∞	∞	∞	\times	\times	\times	\times	\times	\times	\times
T_{21}	13.5	20	22	∞	\times	\times	\times	\times	\times	\times
T_{22}	19	3	6	∞	∞	\times	\times	\times	\times	\times
T_{23}	1	16	20.5	∞	∞	∞	\times	\times	\times	\times
T_{24}	20.5	7	2.5	∞	∞	∞	∞	\times	\times	\times
T_{31}	2	15.5	20	12.5	16.5	1.5	17.5	∞	\times	\times
T_{32}	21	7.5	0.5	17	5	18.5	4.5	∞	∞	\times
T_{41}	5.5	10	18	11	15	6.5	16	4	14	∞

	T_{11}	T_{12}	T_{13}	T_{21}	T_{22}	T_{23}	T_{24}	T_{31}	T_{32}	T_{41}
T_{11}	∞	\times	\times	\times	\times	\times	\times	\times	\times	\times
T_{12}	∞	∞	\times	\times	\times	\times	\times	\times	\times	\times
T_{13}	∞	∞	∞	\times	\times	\times	\times	\times	\times	\times
T_{21}	∞	∞	∞	∞	\times	\times	\times	\times	\times	\times
T_{22}	∞	3	6	∞	∞	\times	\times	\times	\times	\times
T_{23}	1	∞	∞	∞	∞	∞	\times	\times	\times	\times
T_{24}	∞	7	2.5	∞	∞	∞	∞	\times	\times	\times
T_{31}	2	∞	∞	∞	∞	1.5	∞	∞	\times	\times
T_{32}	∞	7.5	0.5	∞	5	∞	4.5	∞	∞	\times
T_{41}	5.5	10	∞	∞	∞	6.5	∞	4	∞	∞

	T_{11}	T_{12}	T_{13}	T_{21}	T_{22}	T_{23}	T_{24}	T_{31}	T_{32}	T_{41}
T_{11}	∞	\times	\times	\times	\times	\times	\times	\times	\times	\times
T_{12}	∞	∞	\times	\times	\times	\times	\times	\times	\times	\times
T_{13}	∞	∞	∞	\times	\times	\times	\times	\times	\times	\times
T_{21}	∞	∞	∞	∞	\times	\times	\times	\times	\times	\times
T_{22}	∞	∞	∞	∞	∞	\times	\times	\times	\times	\times
T_{23}	∞	∞	∞	∞	∞	∞	\times	\times	\times	\times
T_{24}	∞	∞	∞	∞	∞	∞	∞	\times	\times	\times
T_{31}	∞	∞	∞	∞	∞	∞	∞	∞	\times	\times
T_{32}	∞	∞	∞	∞	5	∞	4.5	∞	∞	\times
T_{41}	5.5	10	∞	∞	∞	6.5	∞	4	∞	∞

Groupes : $\{T_{13}, T_{32}, T_{24}\}$
 $\{T_{11}, T_{23}, T_{31}, T_{41}\}$
 $\{T_{12}, T_{22}\}$

	T_{11}	T_{12}	T_{13}	T_{21}	T_{22}	T_{23}	T_{24}	T_{31}	T_{32}	T_{41}
T_{11}	∞	\times	\times	\times	\times	\times	\times	\times	\times	\times
T_{12}	∞	∞	\times	\times	\times	\times	\times	\times	\times	\times
T_{13}	∞	∞	∞	\times	\times	\times	\times	\times	\times	\times
T_{21}	∞	∞	∞	∞	\times	\times	\times	\times	\times	\times
T_{22}	∞	∞	∞	∞	∞	\times	\times	\times	\times	\times
T_{23}	∞	∞	∞	∞	∞	∞	\times	\times	\times	\times
T_{24}	∞	∞	∞	∞	∞	∞	∞	\times	\times	\times
T_{31}	∞	∞	∞	∞	∞	∞	∞	∞	\times	\times
T_{32}	∞	∞	∞	∞	5	∞	4.5	∞	∞	\times
T_{41}	5.5	10	∞	∞	∞	6.5	∞	∞	∞	∞

Groupes : $\{T_{13}, T_{32}, T_{24}\}$
 $\{T_{11}, T_{23}, T_{31}, T_{41}\}$
 $\{T_{12}, T_{22}\}$

	T_{11}	T_{12}	T_{13}	T_{21}	T_{22}	T_{23}	T_{24}	T_{31}	T_{32}	T_{41}
T_{11}	∞	\times	\times	\times	\times	\times	\times	\times	\times	\times
T_{12}	∞	∞	\times	\times	\times	\times	\times	\times	\times	\times
T_{13}	∞	∞	∞	\times	\times	\times	\times	\times	\times	\times
T_{21}	∞	∞	∞	∞	\times	\times	\times	\times	\times	\times
T_{22}	∞	∞	∞	∞	∞	\times	\times	\times	\times	\times
T_{23}	∞	∞	∞	∞	∞	∞	\times	\times	\times	\times
T_{24}	∞	∞	∞	∞	∞	∞	∞	\times	\times	\times
T_{31}	∞	∞	∞	∞	∞	∞	∞	∞	\times	\times
T_{32}	∞	∞	∞	∞	∞	∞	∞	∞	∞	\times
T_{41}	5.5	10	∞	∞	∞	6.5	∞	∞	∞	∞

Groupes : $\{T_{13}, T_{32}, T_{24}\}$
 $\{T_{11}, T_{23}, T_{31}, T_{41}\}$
 $\{T_{12}, T_{22}\}$

	T_{11}	T_{12}	T_{13}	T_{21}	T_{22}	T_{23}	T_{24}	T_{31}	T_{32}	T_{41}
T_{11}	∞	\times	\times	\times	\times	\times	\times	\times	\times	\times
T_{12}	∞	∞	\times	\times	\times	\times	\times	\times	\times	\times
T_{13}	∞	∞	∞	\times	\times	\times	\times	\times	\times	\times
T_{21}	∞	∞	∞	∞	\times	\times	\times	\times	\times	\times
T_{22}	∞	∞	∞	∞	∞	\times	\times	\times	\times	\times
T_{23}	∞	∞	∞	∞	∞	∞	\times	\times	\times	\times
T_{24}	∞	∞	∞	∞	∞	∞	∞	\times	\times	\times
T_{31}	∞	∞	∞	∞	∞	∞	∞	∞	\times	\times
T_{32}	∞	∞	∞	∞	∞	∞	∞	∞	∞	\times
T_{41}	∞	∞	∞	∞	∞	6.5	∞	∞	∞	∞

Groupes : $\{T_{13}, T_{32}, T_{24}\}$
 $\{T_{11}, T_{23}, T_{31}, T_{41}\}$
 $\{T_{12}, T_{22}\}$

Étape 5

Groupes : $\{T_{13}, T_{32}, T_{24}\}$, $\{T_{11}, T_{23}, T_{31}, T_{41}\}$, $\{T_{12}, T_{22}\}$, $\{T_{21}\}$

Ceci est le résultat attendu.

3.5 Estimation d'état de pistes globales

Cette opération consiste à se servir des pistes locales associées à chaque piste globale pour faire une nouvelle estimation de son état et de sa matrice de covariance associée. Avant d'aborder les différentes méthodes de mise à jour, il faut faire quelques remarques qui ont été bien résumées par l'auteur de [Aziz, 2006] où il rapporte les conclusions de plusieurs de travaux [Saha, 1994, Haimovich et al., 1993, Chang et al., 1996][Saha, 1996, Bar-Shalom and Li, 1995] :

- Le résultat de la fusion de données est à peine meilleur voire pire que l'estimation du meilleur capteur si les capteurs utilisés ont des précisions très différentes ou si leurs variances sont très grandes.
- On obtient les meilleures performances si les capteurs sont de natures semblables (même principe de mesure).

Il est ainsi recommandé de n'effectuer une véritable fusion de données que si les capteurs ont des performances semblables. Dans le cas contraire, il faut simplement adopter le résultat du meilleur capteur ; on parle alors de fusion de données disjonctive. Cela consiste à sélectionner pour chaque paramètre d'état à estimer, la valeur fournie par le capteur dont on sait a priori qu'il est le plus performant pour la mesure de ce paramètre. Dans la suite de cette étude, les capteurs sont supposés avoir des performances semblables, ce qui justifie la fusion de données, mais peuvent être de natures différents.

3.5.1 Fusion multi-capteur par filtrage de Kalman

La méthode de mise à jour de piste la plus célèbre est sans doute le filtre de Kalman. Considérons d'abord un cas mono-capteur. Soit une piste dont l'estimation d'état à l'instant t_{k-1} est notée $X_{k-1|k-1}$. Son nouvel état $X_{k|k}$, estimé à l'instant t_k à partir d'une mesure Y_k qui lui est associée, est donnée par la formule du filtre de Kalman suivante :

$$X_{k|k} = X_{k|k-1} + K_k (Y_k - H \cdot X_{k|k-1})$$

où $X_{k|k-1}$ est la prédiction d'état de la piste pour l'instant t_k à partir de l'instant t_{k-1} . K_k est le gain du filtre, et H est la matrice de passage de l'espace d'état à l'espace de mesure. Le gain est calculé de façon à ce que l'erreur d'estimation soit "orthogonale" aux erreurs de prédiction et de mesure, sous hypothèse que les bruits de mesure et de modèle sont blancs. Son expression est la suivante :

$$K_k = P_{k|k-1} \cdot H^T (H \cdot P_{k|k-1} \cdot H^T + R)^{-1}$$

où $P_{k|k-1}$ est la matrice de covariance d'erreur d'estimation prédite et R est la matrice de covariance d'erreur de mesure (supposée constante ici).

La matrice de covariance de l'erreur d'estimation peut par exemple se calculer avec la forme suivante :

$$P_{k|k} = (I - K_k \cdot H) P_{k|k-1}$$

où I est la matrice identité.

Lorsqu'on considère un système multi-capteur, il y a potentiellement plusieurs observations associées à une piste système. Numérotons ces observations de (1) à (N). Il existe dans la littérature [Willner et al., 1976], plusieurs architectures de mise à jour pour éviter d'avoir à inverser une matrice de taille importante lors des estimations. On suppose dans ce qui suit que les erreurs de mesures sont indépendantes.

Une première approche, dite séquentielle, consiste à fusionner les observations une à une successivement, en utilisant la formule du cas mono-capteur. Le résultat de chaque fusion est utilisé comme prédiction pour fusionner l'observation suivante. Elle est très utilisée dans le cas où le nombre de capteurs est "petit" par rapport à la dimension de l'état.

Une autre approche, dite parallèle, consiste quant à elle à faire la fusion des données de capteurs en une seule étape. Une erreur parfois rencontrée consiste à rajouter l'innovation de chaque observation à la prédiction, ce qui donne la formule (fausse) suivante :

$$X_{k|k} = X_{k|k-1} + \sum_{i=1}^N {}^i K_k \left({}^i Y_k - {}^i H \cdot X_{k|k-1} \right)$$

avec

$${}^i K_k = P_{k|k-1} \cdot {}^i H^T \left({}^i H \cdot P_{k|k-1} \cdot {}^i H^T + {}^i R \right)^{-1}$$

Il faut cependant remarquer que les innovations ${}^i K_k \left({}^i Y_k - {}^i H \cdot X_{k|k-1} \right)$ des observations ne sont pas indépendantes entre elles, puisqu'elles résultent d'une même prédiction d'état. Une démonstration est disponible dans le polycopié de cours de Durrant-Whyte [Durrant-Whyte, 2006].

Pour faire la fusion parallèle de façon efficace (notamment quand le nombre de capteurs est grand), il est préférable d'utiliser la forme dite de "covariance inverse" qui calcule d'abord l'estimation de la matrice de covariance pour en déduire l'estimation d'état. Les formules sont les suivantes (toujours sous hypothèse d'indépendance des erreurs de mesure) :

$$P_{k|k}^{-1} = P_{k|k-1}^{-1} + \sum_{i=1}^N {}^i H^T \cdot {}^i R^{-1} \cdot {}^i H$$

$$X_{k|k} = P_{k|k} \left(P_{k|k-1}^{-1} \cdot X_{k|k-1} + \sum_{i=1}^N {}^i H^T \cdot {}^i R^{-1} \cdot {}^i Y_k \right)$$

Dans certains cas, la matrice de passage H est égale à la matrice identité (i.e. espace de mesure égal à espace d'état) et on peut en quelque sorte considérer que les prédictions $X_{k|k-1}$ et $P_{k|k-1}$ et les capteurs sont tous des estimateurs de l'état de la piste considérée. En notant X_i ces estimations obtenues à un instant donné et P_i les matrices de covariance, on obtient la formule générale de fusion suivante (le style notation change car le paramètre temps n'intervient plus) :

$$P^{-1} = \sum_{i=1}^N P_i^{-1} \quad (3.6)$$

$$X = P \sum_{i=1}^N P_i^{-1} X_i \quad (3.7)$$

Dans le cas classique de la combinaison des deux estimateurs (a) et (b), on obtient bien le résultat connu :

$$X = P_b (P_a + P_b)^{-1} X_a + P_a (P_a + P_b)^{-1} X_b \quad (3.8)$$

$$P = P_b (P_a + P_b)^{-1} P_a \quad (3.9)$$

3.5.2 Fusion de pisteurs

Considérons le problème qui consiste à fusionner des pistes déjà suivies localement. Lorsque les erreurs d'estimation sont corrélées, il faut tenir compte de l'inter-covariance entre les erreurs d'estimation respectives pour avoir un résultat optimal. Les résultats de Liggins et Chang dans le chapitre 17 de [Liggins et al., 2008a] montrent que le fait de ne pas en tenir compte pourrait donner au final une matrice de covariance d'erreur d'estimation moins large qu'elle ne l'est en réalité, ce qui correspond à un résultat sur-confiant. Le calcul de l'inter-covariance entre les erreurs d'estimation de deux pisteurs a été discuté dans la section 3.4.3. En se limitant à deux estimateurs (a) et (b), les équations de combinaison optimale au sens du maximum a posteriori sont

$$X = X_a + (P_a - P_{ab}) \left(P_a + P_b - P_{ab} - P_{ab}^T \right)^{-1} (X_b - X_a) \quad (3.10)$$

$$P = P_a - (P_a - P_{ab}) \left(P_a + P_b - P_{ab} - P_{ab}^T \right)^{-1} (P_a - P_{ab})^T \quad (3.11)$$




Figure 3.11: Les ellipses de P (en tirets) obtenues pour diverses valeurs de P_{ab} sont toujours contenues dans la zone d'intersection des ellipses de P_a et P_b (en traits continus). Pour $P_{ab} = 0$, i.e. sous hypothèse d'indépendance, on obtient l'ellipse en trait gras.

où P_{ab} est l'inter-covariance. Lorsque $P_{ab} = 0$ on retrouve bien les équations de base 3.8 et 3.9 supposant une indépendance des données fusionnées.

Lorsque les différents pisteurs utilisent tous le même modèle d'évolution, il est possible d'estimer de façon séquentielle la valeur de l'inter-corrélation à partir d'une valeur donnée a priori (voir [Durrant-Whyte, 2006], page 90). Sinon, l'inter-covariance n'est pas calculable exactement. Il existe des méthodes permettant de faire la fusion en évitant la sur-confiance. Intéressons-nous à l'une d'entre elles, la méthode d'intersection de covariance.

3.5.3 Intersection de covariance

La méthode d'intersection de covariance et ses variantes discutées par exemple dans [Li and Nashashibi, 2012, Chen et al., 2002] et dans [Liggins et al., 2008a], Chapitre 14 résultent d'une interprétation géométrique des équations 3.10 et 3.11 précédentes. En effet, considérons deux estimateurs (X_a, P_a) et (X_b, P_b) de l'état d'un objet ; les paramètres sont respectivement l'estimation et la matrice de covariance d'erreur d'estimation. Pour faciliter l'interprétation, nous allons supposer que les deux estimateurs ont des estimations égales ($X_a = X_b$) mais des matrices de covariance différentes. Soit maintenant (X, P) l'estimateur final obtenu en combinant les deux premiers estimateurs par la formule des équations 3.10 et 3.11. Puisque l'inter-covariance P_{ab} est inconnue, on génère un ensemble de valeurs possible et on fait le calcul pour chaque cas. En traçant les ellipses d'incertitude des deux estimateurs et celle de chaque résultat obtenu, on remarque que quelle que soit la valeur choisie pour P_{ab} , l'ellipse représentant le résultat P est toujours comprise dans l'intersection des ellipses représentant respectivement P_a et P_b (voir figure 3.11).

Cela signifie que, si P_{ab} est inconnue, toute méthode consistant à obtenir une matrice P dont l'ellipse englobe la zone d'intersection évite la sur-confiance. La méthode




Figure 3.12: Les ellipses de P (en tirets) obtenues quelques soit la valeurs de $\omega \in [0, 1]$ englobent toujours la zone d'intersection des ellipses de P_a et P_b (en traits continus). .

d'intersection de covariance est donnée alors donnée par les équations suivantes

$$P = \left(\omega \cdot P_a^{-1} + (1 - \omega) \cdot P_b^{-1} \right)^{-1}$$

$$X = P \left(\omega \cdot P_a^{-1} \cdot X_a + (1 - \omega) \cdot P_b^{-1} \cdot X_b \right)$$

où $\omega \in [0, 1]$ est le poids accordé à l'estimateur (a) . La figure 3.12 illustre le résultat obtenu pour diverses valeurs de ω .

Toutes les ellipses obtenues englobent la zone d'intersection. En pratique, ω est choisi de façon à minimiser le déterminant de P , i.e. pour avoir l'ellipse d'incertitude la plus petite possible.

$$\omega = \arg \min_{\omega} (\det(P))$$

Dans le cas de N estimateurs numérotés de 1 à N , les formules obtenues dans [Qi et al., 2013] sont les suivantes :

$$P = \left(\sum_{i=1}^N \omega_i P_i \right)^{-1}$$

$$X = P \left(\sum_{i=1}^N \omega_i P_i^{-1} X_i \right)$$

où X_i , P_i et ω_i représentent représentation l'estimation, la matrice de covariance et le poids de l'estimateur d'ordre (i) , avec $\omega_i \in [0, 1]$ et $\sum_{i=1}^N \omega_i = 1$. X est l'estimation

finale obtenue et P sa matrice de covariance. Les poids sont choisis de façon à minimiser le déterminant de P .

Cette méthode est sous-optimale mais évite la sur-confiance. Sa mise en œuvre est simple mais la détermination du coefficient ω est un problème d'optimisation non linéaire qui peut engendrer de nombreux calculs.

3.5.4 Approche choisie

Nous avons vu que la prise en compte de l'inter-corrélation des données à fusionner était nécessaire pour avoir un résultat optimal. Or, nous ne pouvons pas calculer cette matrice d'inter-covariance car les paramètres des filtres des capteurs utilisés sont inconnus. Notre choix est donc régi par le besoin de minimiser l'inconsistance générée par l'ignorance de cette matrice.

L'approche proposée consiste à d'abord associer les pistes locales entre elles puis à créer des *super-observations* en fusionnant les pistes associées, par la méthode du filtre de Kalman. Nous les avons appelées super-observations et non super-pistes, par exemple, car elles correspondent à des estimations instantanées qui n'ont pas d'historique ; d'une itération à l'autre, rien ne garantit que les mêmes pistes locales seront toujours associées. Les super-observations obtenues sont ensuite associées avec les prédictions d'état des pistes globales courantes du système puis la mise-à-jour des pistes globales est faite en remplaçant leur état à la dernière itération par celle de la super-observation qui leur est associée (sans faire de sur-fusion). Il n'est pas nécessaire de connaître l'inter-corrélation entre les pistes globales et les super-observations car il n'y a aucune opération de fusion supplémentaire. Cette méthode suppose donc que les super-observations sont des estimées assez correctes des états réels des objets suivis, ce qui n'est pas aberrant puisque chaque piste locale est déjà le résultat d'un filtrage local.

3.6 Estimation des paramètres non cinématiques

Les paramètres non cinématiques ne sont autres que le type des objets et leur largeur. La remarque faite dans la section précédente, proscrivant la fusion de données si les capteurs ont des performances très dissemblables tient aussi en ce qui concerne la mise à jour des paramètres non cinématiques. En effet, si un capteur est nettement plus performant que les autres pour, par exemple, déterminer le type des objets, il vaut mieux adopter son résultat pour le niveau global. En ce qui concerne le type des objets, il existe un nombre limité de possibilités correspondant chacune à une classe d'objet. Notamment : *piéton, deux-roues, voiture, grand véhicule* et *inconnu*.

Pour la largeur des objets, l'objectif n'est pas de la déterminer au centimètre près ; on admet une valeur maximale possible (2.7m) puis on considère un nombre limité

de classes correspondant à des intervalles adjacents de 10cm de largeur chacun. Les explications données dans la suite de cette section sont valables pour les deux types de paramètres.

3.6.1 Inférence bayésienne

Supposons que pour un paramètre donné, on ait un ensemble de N hypothèses possibles, noté $H = \{h_1, \dots, h_N\}$ et supposons qu'il y ait un ensemble de capteurs K (numérotés de 1 à K) ayant effectué des mesures sur un même objet. En pratique, il s'agit des capteurs dont un piste a été associée à la piste globale de l'objet. Soit $Z = \{z_1, \dots, z_K\}$ l'ensemble des hypothèses faites par les K capteurs pour la mesure du paramètre considéré. L'objectif est de déterminer les $P(h_i|Z)$ représentant la probabilité de chacune des hypothèses de H sachant l'ensemble des mesures Z . L'hypothèse choisie est alors celle ayant la plus grande probabilité. D'après la règle de Bayes et la règle des probabilités marginales, on peut écrire

$$P(h_i|Z) = \frac{P(Z|h_i) P(h_i)}{\sum_{j=1}^N P(Z|h_j) P(h_j)} \quad (3.12)$$

où $P(h_i)$ est la probabilité a priori de retenir hypothèse h_i . Par exemple il peut s'agir de la probabilité à priori que l'objet soit une voiture. En pratique, on peut supposer une équiprobabilité où de façon plus élaborée, tenir compte de la situation de conduite et de résultats statistiques connus (en ville ou sur autoroute, heure de pointe ou heure creuse etc.). $P(Z|h_j)$ est la probabilité d'avoir cet ensemble de mesures Z sachant que l'hypothèse h_j est vraie. Si les mesures des capteurs pour les paramètres non cinématiques sont supposées indépendantes, on a

$$P(Z|h_j) = P(z_1, z_2, \dots, z_K|h_j) = \prod_{k=1}^K P(z_k|h_j)$$

On obtient alors pour l'équation 3.12, la forme

$$P(h_i|Z) = \frac{P(h_i) \prod_{k=1}^K P(z_k|h_i)}{\sum_{j=1}^N \left(P(h_j) \prod_{k=1}^K P(z_k|h_j) \right)}$$

$P(z_k|h_j)$ est la probabilité que le capteur d'ordre k fournisse la l'hypothèse z_k sachant que l'hypothèse h_j est vraie. Sa valeur provient de la documentation du capteur en question ou d'une expérimentation réalisée à cet effet.

Remarquons que la mise en œuvre de cette méthode demande de connaître certaines probabilités a priori qui, en pratique, ne sont souvent pas disponibles ou sont difficiles

à obtenir. Une autre méthode, plus simple que nous avons mise en œuvre, peut être vue comme un mécanisme de vote.

3.6.2 Mécanisme de vote

Cette solution est sans doute la plus simple à mettre en œuvre. Elle se résume à la formule suivante

$$P(h_i|Z) = \frac{1}{K} \sum_{k=1}^K P_k \cdot P(h_i|z_k)$$

où $P(h_i|z_k)$ représente le “vote” du capteur k

$$\begin{cases} P(h_i|z_k) = 1 & \text{si } z_k = h_i \\ P(h_i|z_k) = 0 & \text{sinon} \end{cases}$$

et où P_k est la probabilité a priori que le capteur k fournisse l’hypothèse vraie. Sa valeur provient d’une connaissance empirique du capteur ou bien de sa documentation. La connaissance empirique peut être le fruit d’une expérimentation consistant à réaliser un grand nombre de roulages puis à calculer le rapport du nombre de bonnes classifications sur le nombre total de classifications effectuées, ce qui est assez simple à réaliser.

3.7 Gestion de la confiance en l’existence des pistes globales

Il arrive parfois qu’un capteur retourne une ou plusieurs détections qui ne correspondent pourtant à aucun objet réel dans la scène ; on parle de détection fantôme ou encore de faux positif. Inversement, il arrive aussi qu’un capteur manque de détecter un objet qui se situe pourtant dans son champ de perception ; on parle de non-détection ou encore de faux négatif. Ces erreurs, au niveau local de chaque capteur, ont des répercussions sur le niveau global ; par exemple, un faux positif peut être à l’origine de la création d’une nouvelle piste globale qui n’a pas lieu d’exister. Afin de réduire ces effets néfastes, on développe un module de traitement qui gère la confiance en l’existence de chaque piste globale du système. Le niveau de confiance est utilisé pour confirmer ou rejeter l’existence d’une piste globale au plus tôt. Lorsque le niveau de confiance est en dessous d’un seuil défini, la piste n’est pas maintenue. Si au contraire, il est supérieur à un autre seuil défini, la piste est confirmée. Le niveau de confiance d’une piste est mis à jour régulièrement pour correspondre à

la situation courante. Plusieurs méthodes d'estimation du niveau de confiance sont proposées dans la littérature. Dans [Aeberhard et al., 2011, Fayad, 2009] les auteurs utilisent les fonctions de croyance pour finalement obtenir une probabilité d'existence de la piste. Le score de Sittler [Sittler, 1964] qui est une méthode bayésienne exprime la confiance à travers un rapport de vraisemblance. Plutôt que d'exprimer un niveau de confiance puis de le comparer à des seuils pour confirmer ou infirmer l'existence d'une piste, nous proposons une méthode utilisant une machine à état (comme dans [Lim et al., 2011]) où nous attribuons directement à la piste, un état qui définit si elle doit être supprimée ou non. Dans cette section, nous allons présenter ces deux dernières approches.

3.7.1 Score de Sittler

Considérons une piste globale mise à jour à un instant donné grâce à K pistes locales de capteurs. Chacun des capteurs fournit une estimation de la probabilité que sa piste correspondent à un objet réel. Soit $Z = \{z_1, \dots, z_K\}$, l'ensemble des K valeurs. Soient les deux hypothèses suivantes :

- H_1 : la piste globale correspond à un objet réel
- H_2 : la piste globale correspond à un objet fantôme.

La probabilité de H_1 sachant l'ensemble Z peut être écrite sous la forme

$$\begin{aligned} P(H_1|Z) &= \frac{P(Z|H_1) P(H_1)}{P(Z)} \\ &= \frac{P(Z|H_1) P(H_1)}{P(Z|H_1) + P(Z|H_2)} \end{aligned}$$

Le score de Sittler [Sittler, 1964] est une méthode classique pour gérer la confiance d'une piste. Il repose sur l'évaluation relative des probabilités des deux hypothèses.

Combinaison de deux pisteurs

On considère deux pisteurs indépendants utilisant des capteurs différents.

Après une étape d'association, deux pistes sont jugées correspondre au même objet. La fusion des estimations cinématiques peut se faire avec un filtre de Kalman par exemple. Considérons la fusion de la confiance dans ce paragraphe.

On suppose un cas simplifié dans lequel chaque pisteur est capable de quantifier la probabilité d'une hypothèse $P(H|y)$ à partir de ses mesures capteurs. On note $y_{k:1}^i$ les observations du capteur "i" depuis l'instant initial jusqu'à l'instant courant.

On cherche à calculer $P(H|y_{k:1}^1, y_{k:1}^2)$.

Utilisons la règle de Bayes :

$$\begin{aligned} P(H|y_{k:1}^1, y_{k:1}^2) &= P(H|y_k^1, y_k^2, y_{k-1:1}^1, y_{k-1:1}^2) \\ &= \frac{P(y_k^1, y_k^2|H, y_{k-1:1}^1, y_{k-1:1}^2) \cdot P(H|y_{k-1:1}^1, y_{k-1:1}^2)}{P(y_k^1, y_k^2|y_{k-1:1}^1, y_{k-1:1}^2)} \end{aligned}$$

Supposons les erreurs des capteurs mutuellement indépendantes :

$$P(y_k^1, y_k^2|H, y_{k-1:1}^1, y_{k-1:1}^2) = P(y_k^1|H, y_{k-1:1}^1) \cdot P(y_k^2|H, y_{k-1:1}^2)$$

Ré-utilisons la règle de Bayes pour chacun des termes :

$$\begin{aligned} P(H|y_{k:1}^1, y_{k:1}^2) &= P(y_k^1|H, y_{k-1:1}^1) \cdot P(y_k^2|H, y_{k-1:1}^2) \cdot \frac{P(H|y_{k-1:1}^1, y_{k-1:1}^2)}{P(y_k^1, y_k^2|y_{k-1:1}^1, y_{k-1:1}^2)} \\ &= \frac{P(H|y_k^1, y_{k-1:1}^1) \cdot P(y_k^1|y_{k-1:1}^1)}{P(H|y_{k-1:1}^1)} \cdot \frac{P(H|y_k^2, y_{k-1:1}^2) \cdot P(y_k^2|y_{k-1:1}^2)}{P(H|y_{k-1:1}^2)} \cdot \frac{P(H|y_{k-1:1}^1, y_{k-1:1}^2)}{P(y_k^1, y_k^2|y_{k-1:1}^1, y_{k-1:1}^2)} \end{aligned}$$

Tous les termes d'évidence sont regroupés dans un terme de normalisation, ce qui simplifie l'expression :

$$P(H|y_{k:1}^1, y_{k:1}^2) \propto \frac{P(H|y_{k:1}^1) \cdot P(H|y_{k:1}^2) \cdot P(H|y_{k-1:1}^1, y_{k-1:1}^2)}{P(H|y_{k-1:1}^1) \cdot P(H|y_{k-1:1}^2)} \quad (3.13)$$

On peut noter que :

- $P(H|y_{k-1:1}^1)$ est la confiance du pisteur 1 à l'étape précédente,
- $P(H|y_{k:1}^1)$ est la confiance du pisteur 1 à l'étape courante,
- $P(H|y_{k-1:1}^1, y_{k-1:1}^2)$ est la confiance du nœud central (faisant la combinaison) à l'étape précédente.

Généralisation

Dans le cas d'un nombre de pisteurs supérieur à 2, on généralise facilement la règle de combinaison (3.13). Par exemple, avec 3 pisteurs elle devient :

$$P(H|y_{k:1}^1, y_{k:1}^2, y_{k:1}^3) \propto \frac{P(H|y_{k:1}^1).P(H|y_{k:1}^2).P(H|y_{k:1}^3).P(H|y_{k-1:1}^1, y_{k-1:1}^2, y_{k-1:1}^3)}{P(H|y_{k-1:1}^1).P(H|y_{k-1:1}^2).P(H|y_{k-1:1}^3)}$$

Cette formule séquentielle suppose qu'une piste globale est toujours mise à jour par les mêmes pisteurs locaux, car le terme $P(H|y_{k-1:1}^1, y_{k-1:1}^2, y_{k-1:1}^3)$ qui correspond à la probabilité obtenue à la dernière itération, fait apparaître tous les pisteurs locaux. Or dans notre cas, d'une étape à l'autre, une même piste globale n'est pas forcément mise à jour par les mêmes pistes locales. Compte tenu de cette remarque, étudions une alternative non probabiliste utilisant une machine à états.

3.7.2 Machine à états

Y-C. Lim et al. proposent dans [Lim et al., 2011] une méthode de gestion de la création et de la suppression des pistes utilisant une machine à états. Quatre états possibles sont définis pour une piste :

- IDLE, il s'agit d'un état fictif symbolisant la non-existence de la piste ; avant sa création ou après sa suppression.
- PRE-TRACK, piste dont l'existence n'est pas encore confirmée
- TRACK, piste dont l'existence est confirmée.
- POST-TRACK, ancienne piste confirmée dont l'existence est moins certaine.

Le passage d'un état à l'autre est fait par un ensemble d'évènements liés aux détections des capteurs. Nous avons adapté ce principe à notre cas en définissant nos propres évènements. Le passage d'un état à l'autre est défini par le diagramme suivant.

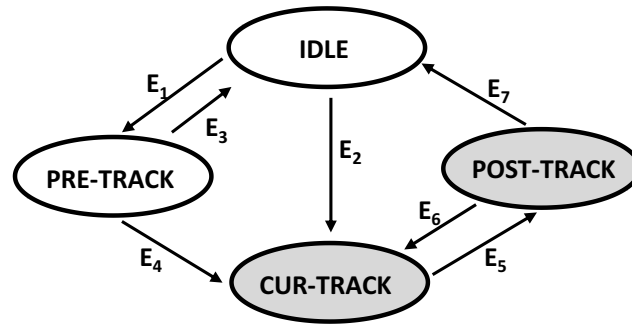


Figure 3.13: Machine à états pour la gestion de pistes

Les évènements E_1 à E_6 dépendent de la valeur de deux scores : le *score de détection* S_D et le *score de persistance* S_P .

- Le score de détection à un instant donné exprime le taux de détection d'un objet vis-à-vis du nombre de capteurs. Il est déterminé à l'aide de l'équation 3.14 où $n_{detection}$ est le nombre de capteurs ayant détecté l'objet, c'est-à-dire le nombre de pistes associées puis fusionnées pour estimer l'état de l'objet, et $n_{visibility}$ le nombre total de capteurs ayant une visibilité sur la position estimée de l'objet.

$$S_D = \frac{n_{detection}}{n_{visibility}} \quad (3.14)$$

$n_{visibility}$ est déterminé grâce au champ de perception des capteurs. Ce champ n'étant pas toujours nettement délimité, il faut considérer, pour chaque capteur, l'espace où la confiance de perception est élevée. Le score de détection est prépondérant dans la gestion de la confiance en l'existence d'un objet et prend tout son sens lorsque le nombre total de capteurs tend à être grand. En effet, lorsque plusieurs capteurs détectent indépendamment un même objet alors la probabilité que l'objet existe soit un faux positif est faible. Par contre, lorsqu'un objet est détecté par un seul capteur alors qu'il se trouve dans le champs de plusieurs capteurs alors les chances que ce soit un faux positif sont plutôt fortes. Si $n_{visibility}$ est nul, le score de détection est aussi défini nul pour que la gestion de la confiance soit faite avec le score de persistance. En effet, cela signifie que l'objet se trouve dans une zone où la probabilité qu'il soit perçu par un capteur est faible.

- Le score de persistance à un instant donné exprime le caractère récurrent de la détection d'un objet par au moins un capteur. Il est calculé à l'aide de l'équation 3.15 où n_{update} est le nombre d'itérations où la piste a été effectivement mise à jour par de nouvelles données et n_{age} est le nombre d'itérations depuis que l'objet a été détecté pour la première fois.

$$S_P = \frac{n_{update}}{n_{age} + 1} \quad (3.15)$$

A la première détection d'une cible, S_P vaut donc 1/2. Le tableau 3.1 montre le mécanisme de déclenchement des événements E_1 à E_7 .

Les seuils s_D , s_{Pinf} et s_{Psup} sont des paramètres réglables compris entre 0 et 1 avec $s_{Pinf} \leq \frac{1}{2} < s_{Psup}$. Nous proposons une discussion à ce sujet lors de l'analyse des résultats expérimentaux sur cette partie.

Le seuil s_{Pinf} est un score minimum de persistance pour que la piste soit considérée sans pour autant être confirmée; en dessous de ce seuil la piste est supprimée car on estime qu'elle n'a pas été assez observée depuis sa création. Le seuil s_{Psup} est un score de persistance au delà duquel on estime que la piste a suffisamment été observée et mise à jour pour être considérée comme réelle même si elle n'a été vue que par un seul capteur. Le choix de la valeur de ces seuils dépend du taux de faux positifs des capteurs concernés. S'ils ont tendance à remonter beaucoup de faux positifs les seuils doivent être élevés. Un capteur ayant un même faux positif très récurrent peut fausser le mécanisme mais ce problème est considéré comme aberrant

Évènement	État initial de la piste	Test à passer	État final de la piste
E_1	IDLE	$S_D < s_D$	PRE-TRACK
E_2	IDLE	$S_D \geq s_D$	CURR-TRACK
E_3	PRE-TRACK	$S_P < s_{P_{inf}}$	IDLE
E_4	PRE-TRACK	$S_D \geq s_D$ ou $S_P \geq s_{P_{sup}}$	CURR-TRACK
E_5	CURR-TRACK	$S_D < s_D$ et $S_P < s_{P_{sup}}$	POST-TRACK
E_6	POST-TRACK	$S_D \geq s_D$ ou $S_P \geq s_{P_{sup}}$	CURR-TRACK
E_7	POST-TRACK	$S_P < s_{P_{inf}}$	IDLE

Table 3.1: Mécanisme de passage d'un état à l'autre

et doit être réglé autrement. Le seuil de détection peut respecter un mécanisme de vote où la majorité l'emporte c'est-à-dire qu'il est égal à la moitié du nombre de capteurs concernés avec un arrondi par excès si le nombre de capteur est impair.

3.8 Résultats et analyses

3.8.1 Évaluation de l'association et de la fusion de pistes sur des données simulées

Description de la simulation

A l'aide du simulateur que nous avons développé, nous avons généré un scénario urbain incluant 5 véhicules, dont l'égo-véhicule. Ce dernier ainsi que deux autres véhicules, notés V_1 et V_2 , roulent dans la même direction, avec des vitesses différentes, sur une section de route rectiligne. L'égo-véhicule suit V_1 , le dépasse puis se fait dépasser par V_1 . V_2 les dépasse ensuite tous les deux. Les trois véhicules s'arrêtent ensuite au niveau d'un rond-point pour laisser la priorité aux deux derniers véhicules, notés V_3 et V_4 venant initialement en sens inverse. Au rond-point, V_3 tourne à gauche tandis que V_4 fait demi-tour. L'égo-véhicule, V_1 et V_2 s'engagent ensuite dans le rond-point où V_2 tourne à gauche et V_1 continue tout droit. L'égo-véhicule continue également tout droit et sort donc du rond-point en suivant V_1 et V_4 . Les trois véhicules traversent une section rectiligne puis arrivent enfin à une intersection où V_1 tourne à gauche, V_4 tourne à droite et l'égo-véhicule continue tout droit. Le scénario dure en tout 122s. Les véhicules roulent à une vitesse moyenne de 40km/h.

L'égo-véhicule est équipé de 3 capteurs $S1$, $S2$ et $S3$, tous en perception avant. Leurs champs de perception sont assez redondants pour pouvoir évaluer l'algorithme d'association de pistes dans diverses situations et pour pouvoir comparer le suivi de cible global au suivi effectué par chaque capteur pris individuellement (Fig. 3.14).




Figure 3.14: Aperçu du scénario simulé, avec les 5 véhicules et une représentation des champs de perception des capteurs

Paramètres	Config 1			Config 2			Config 3			Config 4		
	S1	S2	S3	S1	S2	S3	S1	S2	S3	S1	S2	S3
x	2	6	2	2	15	13	2	24	25	10	15	2
y	2	5	3	2	15	16	2	23	24	10	10	2
v_x	3	4	5	3	10	12	3	19	21	2	8	8
v_y	3	4	5	3	10	10	3	19	21	2	8	8

Table 3.2: Configurations de capteurs testées

La simulation a été faite plusieurs fois en variant la précision des capteurs. Nous avons reporté les résultats des 4 configurations décrites dans le tableau 3.2. Les valeurs indiquées dans le tableau sont les écarts-types des erreurs de mesures, exprimées en pourcentage de la valeur réelle. L’erreur de mesure effective à chaque échantillon de mesure est une valeur aléatoire, comme expliqué dans la section 2.4.2 qui décrit le simulateur de données.

Comme on peut le remarquer, de la configuration 1 à la configuration 3, le capteur $S1$ ne change pas, tandis que les $S2$ et $S3$ ont des performances de plus en plus dégradées. Ces 3 configurations sont utilisées pour tester l’algorithme d’association de pistes dans des conditions diverses. La configuration 4 sert au test de la précision du suivi de cible global.

Résultats de l’algorithme d’association de pistes

L’algorithme 3.1 (page 55) que nous avons proposé a deux paramètres de réglage : le seuil de la fenêtre d’association (voir étape 2.d) et la “taille d’historique” définie

pour le calcul du $TTTD$ ¹ (voir équation 3.4). Nous avons étudié l'impact de chaque paramètre sur les résultats, i.e. sur le taux d'erreurs d'association. La simulation complète du scénario a été faite 5 fois par configuration de capteurs (configuration 1 à 3) et par valeur choisie pour chaque paramètre de réglage. Pour une exécution complète du scénario, l'algorithme est exécuté environ 400 fois (à chaque instant échantillonné où il y a au moins un objet détecté).

Les erreurs d'association ont été de deux types :

1. Deux pistes locales permutant leur groupe d'association : Cette erreur peut se produire lorsque les deux objets correspondants se déplacent de façon très proche l'une de l'autre pendant un temps supérieur à la taille d'historique choisie. L'avantage du $TTTD$ est de pouvoir distinguer les pistes qui sont proches seulement pendant un moment de celles qui ont toujours été proches parce qu'elles sont probablement issues de la cible réelle. Si l'historique considéré n'est pas assez grand, cette distinction peut ne pas être faite et le manque de précision peut, par moment, engendrer une erreur d'association (voir figure 3.15.a). Une solution possible est d'élargir la taille de l'historique considérée mais cela engendre plus de calculs. Dans notre cas de simulation, augmenter la taille d'historique d'un pas d'échantillonnage augmente le temps d'exécution de 1% environ. Cela s'empire si le nombre de capteurs et/ou le nombre de cibles augmentent.
2. Plus de groupes de pistes que de cibles réelles : cette erreur se produit lorsqu'un capteur produit une piste fantôme ou lorsqu'une piste dont l'état est très mal estimé sort de la fenêtre d'association qui lui correspond (voir figure 3.15.b). La solution est d'élargir le seuil de la fenêtre d'association mais cela augmente le nombre de calcul (plus de pistes à considérer dans la fenêtre) et peut conduire à associer des pistes qui ne correspondent pas à une même cible.

Un troisième type d'erreur possible mais que nous n'avons pas eu pendant nos simulations, est d'obtenir moins de groupes de pistes que de cibles réelles. En effet, si le seuil de la fenêtre d'association est défini trop grand et s'il y a des non détections, certaines pistes locales issues d'objets différentes peuvent être associées (voir figure 3.15.c). Toutefois, ce type d'erreur devrait être très rare car il faudrait que chaque capteur ait une non détection dans la zone de redondance ; en effet si au moins un capteur n'a pas de non détection, le nombre de groupes sera au moins égal au nombre de d'objets.

Le tableau 3.3.a montre le taux d'erreurs d'association (en pourcentage) en fonction de la valeur du seuil de la fenêtre d'association, avec la taille d'historique fixée à 10 périodes d'échantillonnage, soit 1s. On peut remarquer que plus les capteurs sont imprécis (configurations 2 et 3), plus la fenêtre d'association doit être large pour avoir moins d'erreurs. On peut difficilement établir une relation mathématique entre la précision des capteurs et le seuil à utiliser car la distribution statistique que

1. Track-To-Track Distance




Figure 3.15: Erreurs d'association. Les cibles réelles sont représentées en noir et les pistes capteur en couleur. a) Permutation de groupe b) Plus de groupes que de cibles c) Moins de groupes que de pistes

	Seuil de la fenêtre					Taille de l'historique			
	10	12	15	20	30	1	5	10	
Config 1	0.8	0	0	0	0	Config 1	19	10.8	0
Config 2	83.3	31.2	1	0	0	Config 2	20.3	17.4	0
Config 3	87.1	42.3	5	4.2	0	Config 3	37.7	20.3	0

(a) (b)

Table 3.3: Pourcentage d'erreur d'association en fonction de (a) la taille de la fenêtre d'association et (b) la taille de l'historique.

respecte l'expression du $TTTD$ (équation 3.4) n'est pas connue. La bonne valeur peut être déterminée expérimentalement.

Le tableau 3.3.b montre le taux d'erreurs d'association en fonction de la taille d'historique choisie. La taille de la fenêtre d'association a été fixée à 30. On peut remarquer que tenir compte de plus d'états passés des pistes résout les situations ambiguës dues à la proximité temporaire de certaines objets et conduit à moins d'erreurs d'association.

Quelle que soit la précision des capteurs, il est possible de paramétrer l'algorithme de façon à ce qu'il donne de bons résultats mais il faut porter attention au temps de calcul nécessaire.

Résultats du suivi global

Pour évaluer la performance de la méthode de suivi de cibles global, nous avons utilisé la configuration 4, décrite dans le tableau 3.2, pour la précision des capteurs. Le capteur $S1$ est plutôt précis pour l'estimation de la vitesse des cibles, $S3$ pour l'estimation de leur position et $S2$ est peu précis pour les deux. Le seuil choisi pour

le fenêtrage est 30 et la taille de l'historique est 10. La figure 3.16 montre les erreurs de position et de vitesse longitudinales pour l'une des cibles. Les résultats rapportés sont ceux de la méthode d'estimation par filtrage de Kalman décrit dans la section 3.5.1. Les courbes en couleur sont les erreurs du suivi de la cible pour chaque capteur et la courbe en trait gras noir montre l'erreur pour le suivi d'objets global.




Figure 3.16: Comparaison des erreurs du suivi global et celles des suivi individuels des capteurs

On peut remarquer que l'estimation d'état global est toujours plus proche de l'estimation faite par le capteur le plus précis pour chaque paramètre d'état, ce qui fait que le suivi de cible global est globalement meilleur que le suivi de chaque capteur pris indépendamment. Cela peut être vérifié avec le tableau 3.4 montrant les erreurs quadratiques moyennes.

	$x(m)$	$y(m)$	$v_x(m/s)$	$v_y(m/s)$
<i>S1</i>	0.5098	0.2671	0.1433	0.1373
<i>S2</i>	0.7831	0.3579	2.7090	2.3812
<i>S3</i>	0.0801	0.0389	0.9991	0.8709
<i>Global</i>	0.0621	0.0334	0.4922	0.4219

Table 3.4: Erreurs quadratiques moyennes

3.8.2 Évaluation sur des données réelles pré-enregistrées

Les résultats présentés dans cette partie, ont été obtenus grâce à une application développée en langage C++ sous Visual Studio. L'application exécute les algorithmes développés et gère l'affichage des résultats en temps-réel, avec un PC standard, pour les configurations matérielles et les environnements de roulage décrits. Les tests ont été faits sur des données de roulage pré-enregistrées.

Résultat de l'algorithme d'association et de la gestion de la confiance des pistes globales

Les résultats rapportés pour ces deux algorithmes ont été obtenus au cours de la même expérimentation. Il s'agit d'un roulage urbain à Versailles, en situation de conduite "normale". Nous avons sauvegardé les données des capteurs et les mesures proprioceptives de l'égo-véhicule afin de faire tourner les algorithmes sur table et d'analyser les résultats. Le véhicule expérimental a été présenté dans le chapitre précédant (section 2.4.1). Pour cette manipulation, nous ne considérons que les 3 capteurs montés à l'avant du véhicule car c'est le secteur le plus redondant. Grâce à l'interface de visualisation (voir figure 3.17), nous pouvons voir les détections de chaque capteur.




Figure 3.17: Interface de visualisation du scénario enregistré. Chaque couleur représente un capteur. Les lignes magenta représentent les points de contour des objets pistés par le lidar, les losanges verts représentent les pistes du radar et les rectangles cyan représentent les pistes de la caméra. Les symboles dessinés en noirs sont les objets détectés par les capteurs et identifiés comme immobiles.

Pour l'algorithme d'association, l'objectif est de vérifier que les pistes locales de chaque capteur sont mises en correspondance avec les bonnes pistes locales des autres capteurs. Pour la gestion de la confiance, il s'agit de vérifier d'une part que toutes les pistes globales confirmées (dans l'état CUR-TRACK ou POST-TRACK) correspondent bien à des objets réels et, d'autre part, que chaque objet réel détecté par au moins un capteur ou non observé depuis peu est bien dans l'état CUR-TRACK ou dans l'état POST-TRACK. Pour connaître la vérité terrain, nous avons enregistré une séquence vidéo du scénario, permettant de faire une vérification visuelle des résultats. Grâce à l'interface de visualisation, nous dessinons dans un même repère les pistes locales de chaque capteur et toutes les super-observations obtenues après la fusion de pistes locales associées, rendant ainsi compte des résultats de l'association de données. Nous traçons également les pistes globales qui sont dans l'état CUR-TRACK et celle qui sont dans l'état POST-TRACK. Avec la vidéo témoin et la date correspondant à chaque image, nous pouvons ainsi vérifier si les résultats à un instant donné sont corrects (voir figure 3.18)

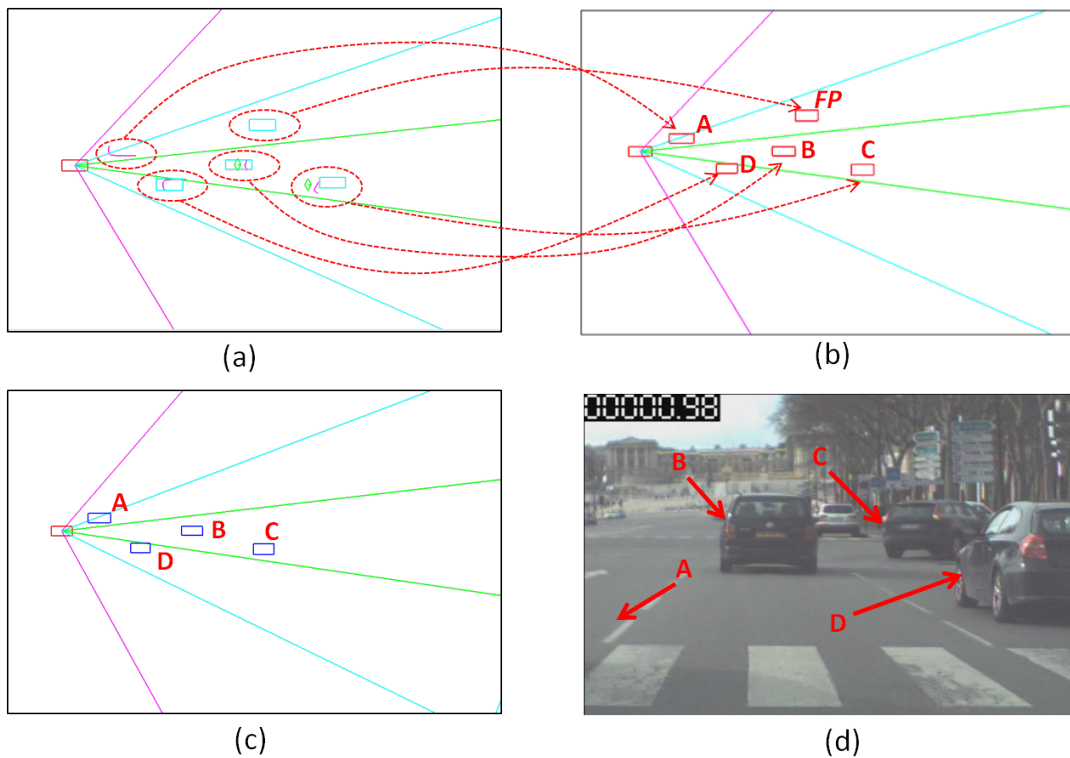


Figure 3.18: La vérification des résultats se fait à partir de la visualisation des pistes locales des capteurs (a), des super-observations (b), des pistes globales confirmées (c) et de la vidéo témoin (d). FP désigne un Faux Positif, obtenu ici par la caméra, et qui est ensuite supprimé des pistes globales par gestion de la confiance

Nous avons ainsi pu compter à chaque période de fusion, le nombre d'erreurs d'association, le nombre de Faux Positifs (FP) et le nombre de Faux Négatifs (FN). La

	Lidar	Radar	Caméra	Global
FP	6.72%	1.57%	4.48%	0.4%
FN	25.37%	45.27%	1.50%	0.1%

Table 3.5: Taux d'erreur

méthode de vérification visuelle n'est sans doute pas la méthode optimale à cause d'une possible erreur humaine lors du décomptage mais nous n'avons pas d'autres moyens pour connaître la vérité terrain en situation normale de conduite. Pour limiter les risques d'erreur, nous avons réalisé des scénarios courts d'environ une à deux minutes. La figure 3.19 en montre un exemple.

Nous avons choisi les valeurs suivantes pour les seuils de détection et persistance mentionnés dans la section 3.7 : $s_D = 2/3$, $s_{P1} = 1/2$ et $s_{P2} = 3/4$. Le tableau 3.5 montre le taux de FP et de FN pour chaque capteur et pour le niveau global. Pour les capteurs nous ne prenons en compte que les zones couvertes par son champ de perception afin de ne pas avoir un taux de FN anormalement élevé. Pour la séquence correspondant à ces résultats, le radar est le meilleur capteur en terme de FP et le pire en terme de FN. Toutefois, son fort taux de FN est dû au fait que durant une bonne partie du scénario, le radar a manqué de détecter un véhicule qui était pourtant dans son champ de perception. La raison de ce fait est inconnue mais nous pensons que la carrosserie du véhicule était sans doute très peu métallisée. On peut toutefois remarquer que malgré ce problème du radar, le taux de FN et de FP au niveau global est très faible et plus faible que ceux de chacun des capteurs.

Le seuil de détection choisi permet de confirmer une piste globale dès qu'elle est observée par au moins 2 capteurs sur 3 dans leur zone de redondance. Ainsi les non-détections du radar n'ont aucun effet tant que les deux autres capteurs ont observé l'objet. C'est pourquoi nous avons un taux de FN global très faible. Il n'est toutefois pas nul car dans les zones non redondantes, il faut attendre une confirmation grâce au score de persistance. Le taux de FP global aussi est très faible car en ce qui concerne le radar et la caméra les objets fantômes détectés ne passent généralement pas le seuil de détection fixé. Mais, il est n'est pas nul non plus car la caméra a eu des artéfacts persistants qui ont fini par passer le seuil de persistance S_{Psup} . Notre perspective pour améliorer les taux de FP et FN est de définir des seuils de persistance différents selon le nombre de capteurs en redondance dans la zone d'intérêt. Ainsi, on peut se permettre d'avoir des seuils de persistance plus faibles dans les zones où il n'y a qu'un seul capteur, cela diminuera le retard systématique de confirmation des nouveaux objets dans les zones non redondantes. Toutefois, si le capteur concerné fournit par défaut beaucoup de FP, ceci pourrait avoir des conséquences néfastes sur le taux de FP global. D'autre part, définir des seuils de persistance plus élevés dans les zones à forte redondance permet de réduire l'influence des artéfacts persistants.

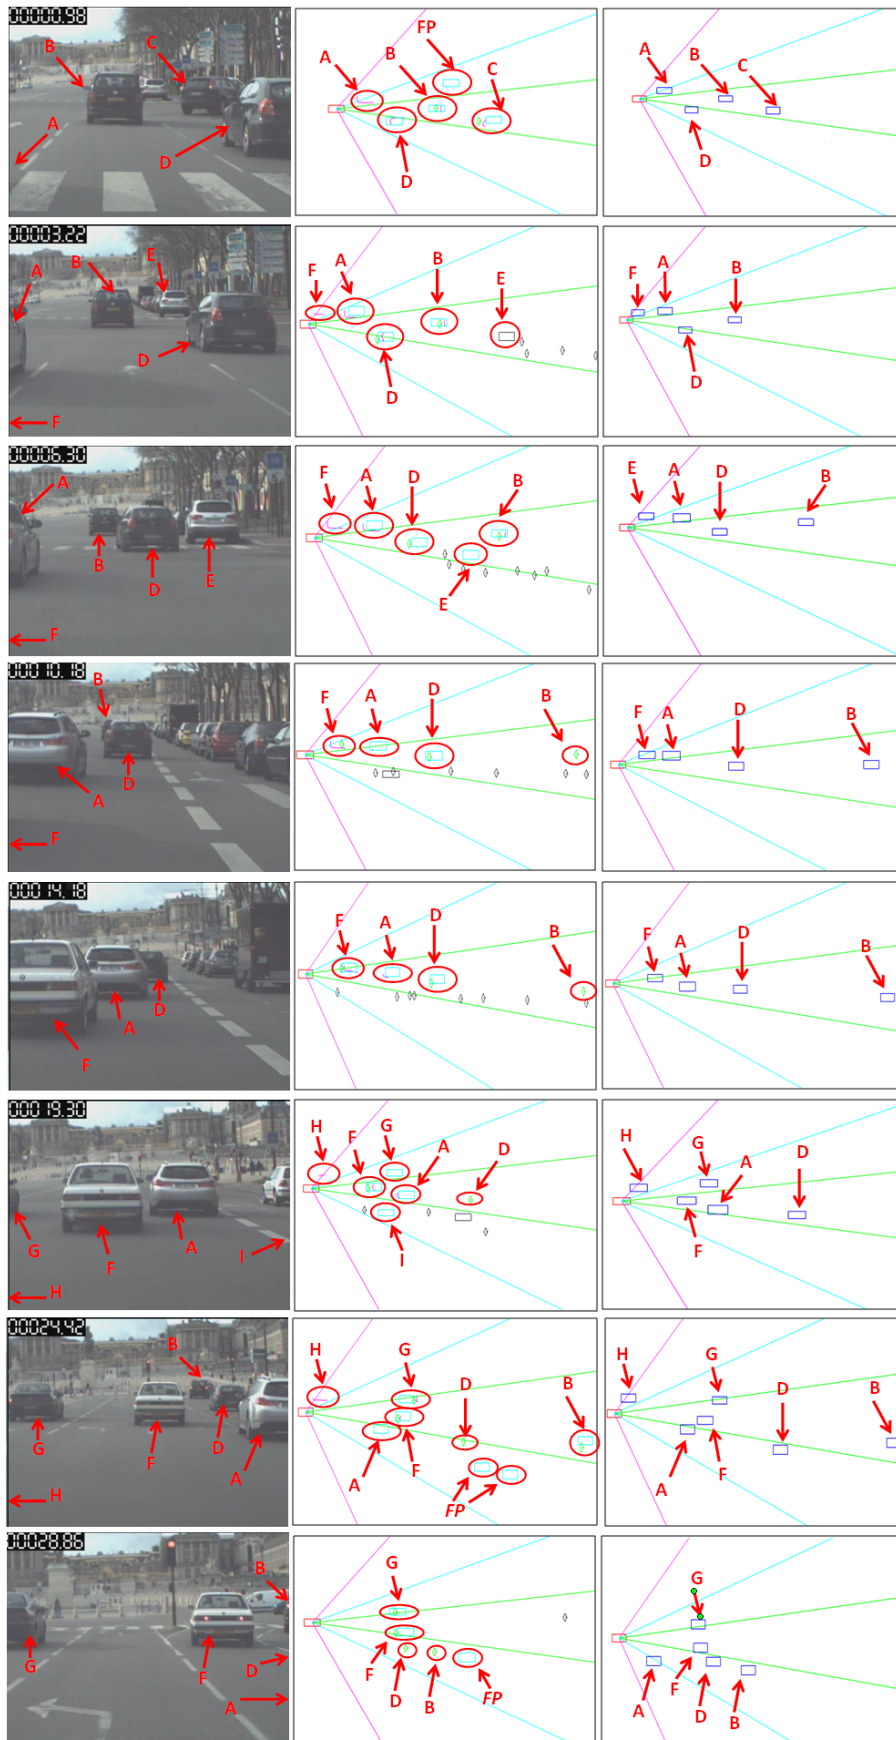


Figure 3.19: Exemple de scénario de test de l'association de pistes locale et de la gestion de la confiance des piste globales. A gauche la vue réelle, au milieu la représentation des pistes des capteurs et à droite les pistes globales confirmées obtenues.

Résultats du suivi global

L'objectif est de rendre compte ici de la précision de l'estimation d'état avec l'approche par filtrage de Kalman décrit dans la section 3.5.1. Pour ce faire, nous avons effectué des manipulations sur piste avec un seul véhicule cible (figure 3.20).



Figure 3.20: Véhicule suivi au cours des essais

L'égo-véhicule et la cible sont équipés d'un dispositif de GPS différentiel afin d'obtenir les mesures de leur position et de leur vitesse relatives avec une très grande précision. Ces mesures relatives nous servent de vérité terrain. Nous avons réalisé plusieurs scénarios au cours desquels la vérité terrain ainsi que les résultats de la fusion de données ont été enregistrés. La figure 3.21 montre les courbes obtenues pour la séparation et la vitesse longitudinales relatives, pour les 3 capteurs à l'avant, ainsi que le résultat de la fusion et la vérité terrain. Le scénario relatif à ces courbes consistait à se rapprocher puis s'éloigner de la cible plusieurs fois en restant derrière elle.

Les discontinuités expriment une perte de la cible (ou une perte de signal GPS pour la vérité terrain). Par exemple, le lidar a perdu la cible pendant environ 3s entre les dates 14s et 17s. La caméra a aussi quelques pertes de cible autour de l'instant 27s. Comme on peut le remarquer, les courbes pour les résultats de la fusion sont continues, ce qui signifie qu'au niveau global on ne perd pas la cible. On note également que lorsque la cible est loin, la caméra et le lidar ont une plus grande erreur mais l'erreur moyenne du résultat de la fusion en est peu affectée. La fusion est globalement plus proche de la vérité que chacun des 3 capteurs utilisés.

3.9 Conclusion

Dans ce chapitre, nous avons passé en revue les étapes classiques d'une opération de suivi de cible en faisant ressortir les particularités imposées notre système, notamment ses caractères multi-capteur, multimodal au niveau piste. Nous avons explicité de nombreuses approches en montrant leur principe ainsi que leurs avantages et




Figure 3.21: Courbes de mesures obtenues : (a) Séparation longitudinale. (b) Vitesse longitudinale relative

inconvenients. La question de l'inter-corrélation entre les données des capteurs intervient à de nombreuses étapes et nous avons rapporté des solutions pour éviter la sur-confiance qu'elle peut engendrer. Nous avons également proposé plusieurs analyses par rapport aux architectures de traitement des données à divers niveaux du processus en explicitant les avantages et les inconvenients de chaque cas. En dehors des étapes classiques de l'opération, nous sommes revenus sur la question de l'alignement temporel et de l'alignement spatial des données qui sont des tâches préalables indispensables, touchant à un aspect plus matériel du module de suivi d'objets (les capteurs).

Nos contributions sont essentiellement un nouvel algorithme d'association de pistes qui est une extension de l'algorithme du plus proche voisin à un nombre quelconque de capteurs, avec une formule de calcul de distance entre pistes qui limite le nombre d'erreurs d'association grâce l'utilisation de l'historique des pistes. L'algorithme a été testé sur des données simulées dans des configurations différentes afin d'évaluer sa robustesse lorsque la précision des capteurs varie. Il a aussi été testé sur des données

réelles et l'ensemble des résultats montre que le taux d'erreur est généralement très faible lorsque le paramétrage est fait convenablement par rapport à la précision des capteurs. Nous avons également proposé une méthode de gestion de la confiance en l'existence des pistes globales, basée sur une machine à états où chaque état correspond à un niveau de confiance donné. Le passage d'un état à l'autre est défini par la valeur d'un Score de Détection et d'un Score de Persistance. La méthode permet de profiter du nombre de capteurs pour confirmer rapidement les pistes correspondant à des objets réels et limiter le nombre de faux positifs. Cette approche a été testée sur des données réelles et les résultats montrent qu'elle garantit une bonne intégrité de la représentation interne du système par rapport à la scène réelle.

Chapitre 4

Analyse de scènes dynamiques

4.1 Introduction

Les ADAS ou les systèmes de sécurité active en général sont une solution prometteuse pour réduire le nombre d'accidents de la circulation [Rieger et al., 2005]. D'ailleurs, certains de ces systèmes existant sur des véhicules en série, font déjà leur preuve. L'ACC (Adaptive Cruise Control), le CWS (Collision Warning System) ou encore l'AEBS (Advanced Emergency Braking System) sont des systèmes capables d'alerter le conducteur voire d'intervenir sur l'état du véhicule lorsque celui-ci tend vers une situation jugée dangereuse afin d'éviter l'accident. Pour cela, ces systèmes sont pourvus d'un module d'analyse de scène qui s'appuie sur une perception continue de l'environnement afin de prédire l'évolution la plus probable de la scène et d'en déduire un niveau de criticité qui définit le niveau d'alerte à émettre ou les actions à faire (suivant les systèmes).

Dans le cas de systèmes d'évitement de collision comme celui étudié dans cette thèse, le niveau de criticité n'est autre que le risque de collision avec les obstacles détectés. L'objectif du Module d'Analyse de Scène est d'évaluer le risque de collision vis-à-vis de chaque obstacle détecté. Pour ce faire, il est nécessaire de prédire la trajectoire des objets mobiles, dont celle de l'égo-véhicule, afin de prévoir une éventuelle future collision. L'horizon de prédiction doit être suffisant pour permettre l'exécution d'une manœuvre d'évitement de collision. Prédire la trajectoire des objets n'est pas une tâche déterministe. En effet, d'une part, la prédiction est basée sur des estimations d'états d'objets qui n'ont pas une précision et une justesse absolues. D'autre part, la trajectoire, d'un véhicule par exemple, dépend de la volonté du conducteur et de nombreux autres paramètres, comme le niveau d'adhérence de la chaussée, qui sont supposés inconnus. Cela dit, il est possible d'approximer la future trajectoire sur un horizon de prédiction de quelques secondes, en faisant certaines hypothèses. Dans plusieurs travaux [Berthelot et al., 2011, Tamke et al., 2011, Polychronopoulos et al., 2004], la prédiction de trajectoire se fait en adoptant un modèle qui décrit le mouvement du véhicule. Les résultats obtenus dans [Schubert et al., 2008] montrent que le modèle à vitesse de lacet et accélération constantes (CYRA¹) donne des résultats plus

1. Constante Yaw Rate and Acceleration

justes que les modèles plus simples supposant un mouvement linéaire ou parfaitement circulaire. Ce type de prédiction, qui sert surtout dans le cadre du suivi d'objets, est particulièrement correct à très courte échéance mais comme on peut le voir sur la figure 4.1, si la manœuvre du véhicule impose un mouvement variable, la prédiction devient largement erronée à long terme. Cette méthode est vue en détails dans la section 4.2.




Figure 4.1: Prédiction de trajectoire erronées car le modèle de prédiction, supposant un mouvement à vitesse de lacet constante n'est pas adapté à la manœuvre en cours.

Afin d'adapter la prédiction de trajectoire à la manœuvre en cours, sur toute la durée de prédiction, de nombreux auteurs [Hülhnagen et al., 2010, Morris et al., 2011, Laugier et al., 2011, Werling et al., 2010] incluent une fonction de Reconnaissance de Manœuvre. Le but est de reconnaître une manœuvre particulière à partir de l'état courant et éventuellement des états passés de l'objet. Ensuite, un modèle plus explicite de trajectoire est utilisé pour prédire les futures poses de l'objet. Des méthodes de Reconnaissance de Manœuvre sont vues dans la section 4.4, où nous présentons également notre propre méthode. Cette dernière est basée sur une modélisation de la route que nous présentons d'abord dans la section 4.3. La section 4.5 discute de la prédiction de trajectoire à partir de la manœuvre reconnue. Dans la section 4.6, nous proposons notre méthode finale de prédiction de trajectoire qui est la combinaison d'une trajectoire prédite grâce à un modèle de mouvement et d'une trajectoire basée sur la Reconnaissance de Manœuvre.

L'estimation du risque de collision est basée sur les trajectoires prédites. La notion de risque de collision entre deux véhicules est intuitivement liée à la notion de temps-avant-collision (TTC¹). En effet, plus le temps disponible pour éviter une éventuelle collision est grand, moins le danger est important et plus la collision semble imminente, plus le danger est grand. La détermination de la valeur exacte du TTC n'est possible que si les trajectoires prédites sont tout aussi justes et précises ; ce qui n'est pas le cas puisque les trajectoires prédites sont sujettes à une incertitude. Le risque de collision s'exprime sous forme de variable stochastique. La section 4.7 revient sur cet aspect.

1. Time-To-Collision

La figure montre un synoptique du fonctionnement du Module d'Analyse de Scène développé.

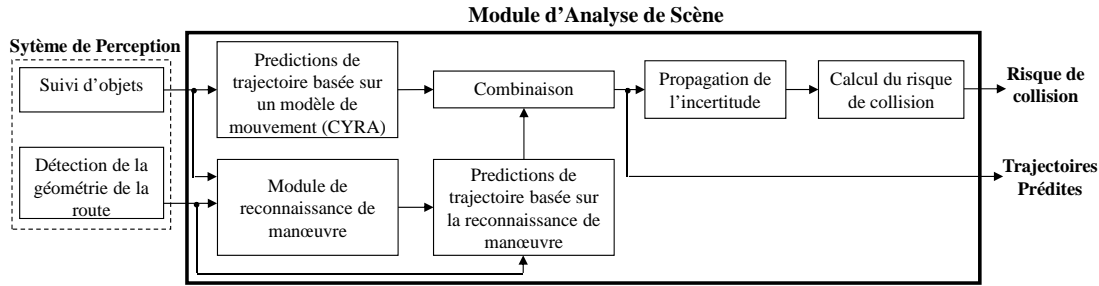


Figure 4.2: Architecture du Module d'Analyse de Scène

4.2 Prédiction de trajectoire basée sur un modèle de mouvement

La modélisation du mouvement d'un objet permet de déterminer son état à un instant quelconque à partir de son état connu à un instant donné et éventuellement d'une séquence de données d'entrée du modèle. Les données d'entrée d'un véhicule sont par exemple l'angle au volant et l'accélération. Dans le cas traité, il s'agit de déterminer les poses futures de l'égo-véhicule et celles des objets détectés. Les futures données d'entrée étant inconnues aussi bien pour l'égo-véhicule que pour les autres objet, nous considérons des modèles sans entrée. Dans un souci de simplicité, nous allons considérer d'une part que tous les objets ont un mouvement de type véhicule, c'est-à-dire qu'ils sont non-holonomes et d'autre part qu'ils se déplacent avec une vitesse de lacet et une accélération tangentielle constantes (modèle CYRA) pour désigner ce type de mouvement. En toute rigueur, il faudrait un modèle bien adapté à chaque type d'objet mais le but de cette thèse ne porte pas sur la modélisation rigoureuse du mouvement de chaque type d'objet. De plus, ce modèle est assez élaboré pour couvrir de nombreux cas.

Considérons un objet (l'égo-véhicule ou une cible quelconque) dont l'état est défini par

$$X = [x, y, \theta, v, a, \omega]^T$$

où (x, y) représentent sa position dans notre repère cartésien de travail tel que défini dans le chapitre 2, θ son angle de lacet, v sa vitesse linéaire, a son accélération tangentielle et ω sa vitesse de lacet.

Pour un état initial, noté $X_0 = [x_0, y_0, \theta_0, v_0, a_0, \omega_0]^T$, et sachant que la vitesse de lacet et l'accélération tangentielle restent constantes, les composantes du vecteur

vitesse en fonction du temps sont données par le système d'équations 4.1

$$\begin{cases} v_x(t) &= (v_0 + a \cdot t) \cos(\theta_0 + \omega \cdot t) \\ v_y(t) &= (v_0 + a \cdot t) \sin(\theta_0 + \omega \cdot t) \end{cases} \quad (4.1)$$

En intégrant chaque composante de la vitesse, on obtient la position du véhicule dans le repère au cours du temps. Le résultat est donné par le système d'équations 4.2 (démonstration en annexe dans la section 6.3)

$$\begin{cases} x(t) &= \frac{v_0 + a_0 \cdot t}{\omega_0} \sin(\theta_0 + \omega_0 \cdot t) + \frac{a_0}{\omega_0^2} \cos(\theta_0 + \omega_0 \cdot t) + c_x \\ y(t) &= -\frac{v_0 + a_0 \cdot t}{\omega_0} \cos(\theta_0 + \omega_0 \cdot t) + \frac{a_0}{\omega_0^2} \sin(\theta_0 + \omega_0 \cdot t) + c_y \end{cases} \quad (4.2)$$

où $\omega_0 \neq 0$ et c_x et c_y sont des constantes définies par l'état initial.

$$\begin{cases} c_x &= x_0 - \frac{v_0}{\omega_0} \sin(\theta_0) - \frac{a_0}{\omega_0^2} \cos(\theta_0) \\ c_y &= y_0 + \frac{v_0}{\omega_0} \cos(\theta_0) - \frac{a_0}{\omega_0^2} \sin(\theta_0) \end{cases}$$

Pour $\omega_0 = 0$, les équations sont les suivantes

$$\begin{cases} x(t) &= x_0 + \left(v_0 t + \frac{1}{2} \cdot a_0 t^2 \right) \cos(\theta_0) \\ y(t) &= y_0 + \left(v_0 t + \frac{1}{2} \cdot a_0 t^2 \right) \sin(\theta_0) \end{cases}$$

Cette méthode de prédiction de trajectoire est surtout adaptée pour les cas où le véhicule reste parfaitement dans sa voie de circulation, ce qui lui donne généralement une trajectoire linéaire (section de route rectiligne), circulaire ou parabolique (dans une courbe). Ainsi, sa trajectoire respecte le modèle utilisé sur une durée de prédiction suffisante. Lorsque le véhicule arrive à une intersection ou lorsqu'il effectue une manœuvre spécifique comme un dépassement, la dynamique de son mouvement peut varier plusieurs fois et rapidement. La prédiction faite n'est alors juste que pour une très courte échéance car les paramètres utilisés initialement pour le modèle ne peuvent pas intégrer les futures variations de régime.

Malheureusement, les statistiques [Martinez et al., 2008] montrent que 50% des accidents arrivent à une intersection ou lors de manœuvres spécifiques. Il convient alors de trouver des solutions mieux adaptées à ces cas particuliers. Pour cela, nous proposons d'utiliser un Module de Reconnaissance de Manœuvre qui détecte au plus tôt la manœuvre en cours et permet ensuite d'utiliser un modèle de trajectoire en fonction de la manœuvre reconnue. La méthode proposée utilise la connaissance des paramètres géométriques de la route. Nous discutons donc d'abord de la modélisation de la route.

4.3 Modélisation de la route

L'objectif de la modélisation de la route est d'obtenir une représentation qui donne les informations nécessaires sur sa géométrie. Notamment, la largeur des voies et la courbe décrite par la route sur un périmètre suffisant. Ces informations servent à faire les prédictions de trajectoire dans le Module d'Analyse de Scène et à calculer la trajectoire d'évitement de collision dans le Module de Décision. La précision et la justesse du modèle sont donc d'une grande importance.

La méthode la plus répandue est probablement celle utilisée pour les cartes numériques embarquées. La route y est représentée sous forme de polygones, comme montré sur la figure 4.3. A chaque segment est associée un certain nombre d'informations utiles comme le nombre de voies, la largeur des voies, la vitesse limite etc. A chaque point est associé un rayon de courbure. La courbe de la route est alors obtenue soit en considérant que le rayon de courbure est constant entre deux points connectés, soit en interpolant linéairement le rayon de courbure, soit encore par des techniques plus élaborées, utilisant les splines [Daniel, 2010]. Afin de profiter de ces informations, il est nécessaire d'effectuer une localisation de l'égo-véhicule sur la carte, grâce à un dispositif GPS¹. On peut alors recueillir des informations sur la zone d'intérêt. Les cartes numériques ordinaires ont en moyenne une précision absolue de $5m$ et une précision relative de $2m$ [Daniel, 2010]. Cette échelle de précision n'est pas suffisante pour une fonction d'évitement de collision car la longueur moyenne d'une voiture varie de $3.10m$ à $3.60m$ (en Europe). De plus, les cartes de navigation standard fournissent une description à l'échelle macroscopique du réseau routier, typiquement une polyligne par section transversale de chaussée. Le détail au niveau voies n'est en général pas disponible, ce qui est problématique vis-à-vis d'une manœuvre de changement de voie par exemple.




Figure 4.3: Modélisation standard de la route par polygones

Une autre solution consiste à utiliser des capteurs pour effectuer une perception directe de la route. Les capteurs vision (caméra) sont alors les mieux adaptés. De nom-

1. Global Positioning System

breuses techniques en traitement d'image permettent de détecter les bords de la route ainsi que les lignes blanches délimitant les voies (transformée de Fourier, transformée de Hough [Quan and Mohr, 1989, Tseng et al., 2005]). Dans [Kluge, 1994, Kluge and Thorpe, 1992], les auteurs extraient un ensemble de points des lignes détectées, puis en faisant l'hypothèse que les lignes sont des arcs de parabole, approximent l'équation de chaque ligne sous la forme d'un polynôme du second degré.

$$y = c_2x^2 + c_1x + c_0 \quad (4.3)$$

où c_2 , c_1 et c_0 sont des coefficients qui dépendent de la détection courante des marquages au sol.

Les techniques de modélisation de la route ne font pas partie des objectifs de cette thèse. Les données nécessaires sur la route nous sont fournies par un module de traitement d'images, sous la forme d'un polynôme de degré 2 ou de degré 3. Dans la suite de l'étude, les équations des lignes de la voie seront supposées connues dans le repère considéré mais pas toujours explicitées afin de rester dans un cadre général. Pour les cas pratiques, un modèle parabolique fourni par le module de traitement d'image sera utilisé (équation 4.3). Ce module fournit également la courbure de la voie, sa largeur ainsi que son orientation en la position du véhicule.

4.4 Module de Reconnaissance de Manœuvre

Le but du Module de Reconnaissance de Manœuvre (MRM) est de reconnaître une manœuvre parmi un ensemble fini, préalablement défini. Plusieurs approches ont été expérimentées dans la littérature.

4.4.1 État de l'art

Dans [Laugier et al., 2011], un ensemble de quatre manœuvres de conduite est prédéfini : *aller tout droit*, *tourner à gauche*, *tourner à droite* et *dépasser*. Pour chacune d'elles, une *trajectoire usuelle* est également prédéfinie. Ensuite, à partir des trajectoires usuelles et de la séquence de données formées par les dernières mesures effectuées, la probabilité d'occurrence de chacune des manœuvres prédéfinies est estimée, en se servant d'un Model de Markov Caché (HMM¹). Les mesures des capteurs contiennent des paramètres comme les distances du véhicule par rapport aux limites gauche et droite de sa voie de circulation, l'activation des clignotants, sa vitesse ou sa proximité à une intersection. La trajectoire usuelle est définie par une séquence de paramètres similaires. L'algorithme du HMM attribue en sortie une

1. Hidden Markov Model

probabilité à chaque manœuvre prédéfinie, à partir de la séquence de mesures en cours. La manœuvre reconnue est donc celle ayant la plus forte probabilité.

Dans [Morris et al., 2011], les auteurs définissent un *contexte de conduite* à l'aide d'un vecteur d'état contenant des mesures de capteurs comme l'activation des clignotants, la direction du regard du conducteur, la distance et l'orientation du véhicule par rapport aux lignes limitrophes de la voie de circulation, la vitesse, etc. Le contexte de conduite est continuellement enregistré sur une fenêtre de 2s pendant que le MRM compare la séquence courante à une base de données d'apprentissage contenant des séquences pré-enregistrées. Le système est alors capable de faire une inférence sur la manœuvre à venir, quelques secondes à l'avance. Cet article effectue en fait de la prédiction de manœuvres et non de la reconnaissance de manœuvres, en se focalisant sur les signes indiquant la préparation à une manœuvre donnée.

[Oliver and Pentland, 2000] utilisent des modélisations graphiques et des HMM pour créer des modèles de 7 manœuvres différentes à partir d'une importante base de données pré-enregistrées. Les manœuvres sont les suivantes : dépasser, changer de voie à gauche et à droite, tourner à gauche et à droite, s'arrêter, démarrer. Les données de l'égo-véhicule ainsi que des données sur la configuration de l'environnement sont continuellement enregistrées puis, la manœuvre la plus probable est reconnue grâce aux modèles créés, en faisant des inférences. Les mesures faites sont par exemple la direction du regard du conducteur, les actions sur la pédale de frein ou les rapports de vitesse du véhicule.

Dans [Hülnhagen et al., 2010], une machine à états probabiliste est utilisée pour modéliser les manœuvres complexes comme une séquence de manœuvres élémentaires définies par des règles simples utilisant la logique floue. Par exemple, une accélération négative équivaut à la manœuvre élémentaire "freiner". L'ensemble des règles est défini à partir de données d'entraînement incluant des mesures comme la vitesse, l'accélération, l'angle au volant, etc. Un filtre bayésien à plusieurs étages est ensuite utilisé pour reconnaître les manœuvres élémentaires puis les manœuvres complexes, à partir de la séquence de données en cours d'enregistrement.

Ce qu'on peut remarquer pour la plupart de ces approches est qu'elles reposent sur une base de données qui sert à l'entraînement du système et que certains signaux (parfois prépondérants) comme l'orientation du regard, l'activation du clignotant, l'angle au volant etc. ne sont généralement disponibles que pour l'égo-véhicule. Dans le contexte de notre étude, il faut prédire aussi bien la trajectoire de l'égo-véhicule que celle des objets détectés. D'autre part, nous ne disposons pas d'une telle base de données. Nous proposons donc une nouvelle méthode, applicable aussi bien à l'égo-véhicule qu'aux autres véhicules détectés, qui repose uniquement sur les mesures effectuées par le Système de Perception.

4.4.2 Approche proposée

En situation de conduite normale (pas de perte de contrôle, hors parking), la trajectoire d'un véhicule dépend des intentions du conducteur qui peuvent être réduites aux manœuvres canoniques suivantes :

- rester sur la voie actuelle : *keep lane*
- changer de voie (aller sur la voie de gauche ou celle de droite) : *change lane*
- changer de route (à une intersection) : *change road*

Une manœuvre de dépassement peut être décomposée en *change lane - keep lane - change lane*. Les manœuvres, et par conséquent la trajectoire du véhicule, sont fortement liées aux voies de la route où il circule. Le MRM¹ que nous proposons est basé sur la mesure de la similitude entre la courbe décrite par la ligne centrale des voies de la route et la courbe très localement décrite par la trajectoire du véhicule.

Pour évaluer cette similitude, chaque courbe est modélisée par un vecteur

$$\xi = [d_l, d_r, \theta, \gamma]$$

Pour la trajectoire du véhicule, d_l et d_r sont respectivement la distance du centre du rectangle englobant du véhicule par rapport aux limites gauche et de droite de la voie (ces deux paramètres définissent le point de départ de la courbe). θ est l'angle de lacet du véhicule, dans le repère de mesure défini et γ est la courbure instantanée de la trajectoire. ξ définit donc un arc de cercle. Les trois premiers paramètres du vecteur ainsi que leurs variances respectives sont facilement obtenus à partir du résultat du Système de Perception. La courbure instantanée de la trajectoire d'un mobile est calculée en faisant le rapport de sa vitesse de lacet par sa vitesse linéaire :

$$\gamma = \frac{\omega}{v} \tag{4.4}$$

où v est la vitesse (non nulle) du véhicule et ω sa vitesse de lacet. En admettant que les paramètres estimés sont normalement distribués et d'après une démonstration effectuée dans [Hayya et al., 1975], la distribution de γ peut être approximée par une gaussienne dont la variance est donnée par l'équation 4.5, valable à condition que la valeur de v ne soit pas proche de zéro.

$$\sigma_\gamma^2 = \left(\frac{\omega \cdot v}{v^2 - \sigma_v^2} \right)^2 - \frac{\omega^2 - \sigma_\omega^2}{v^2 - \sigma_v^2} \tag{4.5}$$

où σ_ω^2 et σ_v^2 sont les variances respectives de ω et v .

1. Module de Reconnaissance de Manœuvres

En ce qui concerne la ligne centrale de la voie considérée, d_l et d_r valent chacun la moitié de la largeur de la voie. L'orientation θ et la courbure γ en un point d'abscisse x dans le repère considéré, sont respectivement déterminées par les équations 4.6 et 4.7, à partir de la fonction $f(x)$ décrivant la ligne.

$$\theta(x) = \arctan(f'(x)) \quad (4.6)$$

$$\gamma(x) = \frac{f''(x)}{(1 + f'(x)^2)^{3/2}} \quad (4.7)$$

Les variances de ces paramètres dépendent de la précision du module de détection de la route.

La distance statistique entre la ligne centrale de la voie et la trajectoire du véhicule est obtenue par l'équation 4.8 et respecte une distribution du χ^2 .

$$D^2 = (\xi_{voie} - \xi_{traj})^T \cdot (\Sigma_{voie} + \Sigma_{traj}) \cdot (\xi_{voie} - \xi_{traj}) \quad (4.8)$$

où Σ_{voie} et Σ_{traj} sont respectivement les matrices de covariance de ξ_{voie} et ξ_{traj} , dont les termes diagonaux sont donnés par les variances des composantes du vecteur ξ . Pour nos expérimentations, nous avons utilisé les valeurs suivantes: $\sigma_{d_l} = \sigma_{d_r} = 0.5m$, $\sigma_\theta = 5^\circ$, $\sigma_\gamma = 0.05m^{-1}$ pour Σ_{voie} . Σ_{traj} est déterminée par les variances des paramètres estimés pour l'objet et par l'équation 4.5.

Si la distance D est inférieure à un seuil donné, alors on estime que les deux courbes sont assez similaires et que le véhicule suit la voie considérée. Pour éviter l'instabilité que pourraient induire des erreurs de mesures ponctuelles ou des petits zigzags à l'intérieur de la voie, la distance utilisée pour le seuillage à un instant t_k est une moyenne pondérée des distances statistiques pour les N derniers instants échantillonnés (voir équation 4.9).

$$D_k^* = \frac{\sum_{i=0}^{N-1} w_i D_{k-i}}{\sum_{i=0}^{N-1} w_i} \quad (4.9)$$

Les poids w_i sont des entiers positifs définis de façon à être plus petits pour les instants les plus anciens car la manœuvre en cours dépend plus des mesures récentes que des anciennes. Pour nos expérimentations, nous avons utilisés les puissances de 2, i.e. $w_i = 2^{N-i}$. Les distances D_{k-i} sont calculées avec l'équation 4.8. La valeur

donnée à N définit une durée d'historique et ne doit pas être trop grande afin de limiter la puissance de calcul nécessaire. Nous utilisons un historique de 1s au maximum.

Le MRM repose sur un Algorithme de Prédiction de Voie (APV) qui permet de prédire la voie sur laquelle le véhicule devrait typiquement aller. L'APV est décrit par l'**Algorithme 4.1** où les distances mentionnées sont calculées à l'aide de l'équation 4.9. Le principe est le suivant : la voie actuelle du véhicule, notée va , est connue grâce au Système de Perception et on calcule sa distance à l'itération courante, notée $D_{k,va}^*$, par rapport à la trajectoire du véhicule. Si cette distance est inférieure au seuil défini, alors on admet que le véhicule va rester sur sa voie actuelle. Si elle est supérieure au seuil mais qu'elle est en décroissance par rapport à sa valeur aux itérations passées, cela signifie que le véhicule vient probablement de rentrer dans cette voie et qu'il tend à bien se centrer. On admet alors aussi que la voie prévue du véhicule correspond à sa voie actuelle. Si la distance est supérieure au seuil et qu'elle est entrain de croître, c'est que le véhicule tend à sortir de sa voie actuelle; dans ce cas, on détermine la distance de sa trajectoire par rapport aux voies connexes à sa voie actuelle puis, celle ayant la plus petite distance est considérée comme voie prévue.

Algorithme 4.1 Prédiction de voie.

```

#la sortie est "vp", la voie prévue du véhicule.
va ← Identifiant de la voie actuelle du véhicule
Dk,va* ← distance entre la trajectoire et la voie actuelle du véhicule, à l'instant
courant
Si (Dk,va* < seuil)
    vp ← va
Sinon
    Dk-1,va* ← distance entre la trajectoire et la voie actuelle du véhicule, à l'instant
    précédent
    si (Dk,va* < Dk-1,va*) #la distance décroît
        vp ← va
    sinon #la distance croît
        n ← nombre de voies connexes
        Dk,v|v=1..n* ← distance entre la trajectoire du véhicule et les voies connexes, à
        l'instant courant
        vmin ← Identifiant de la voie ayant la distance minimale
        vp ← vmin
FinSi
FinSi
Retourner vp

```

Si la voie prévue correspond à la voie actuelle, la manœuvre est un *keep lane*. S'il s'agit d'une voie parallèle alors on a un *change lane*. Sinon, le véhicule se trouve à

proximité d'une intersection et on a un *change road*. Remarquons que pour *change lane* et *change road*, dès que le véhicule aura atteint la nouvelle voie, la manœuvre sera classée *keep lane*.

4.5 Prédiction de trajectoire basée sur la reconnaissance de manœuvre

Une manœuvre correspond à une classe de trajectoires ayant des caractéristiques communes. Pour une même manœuvre reconnue, il y a donc plusieurs possibilités de réalisation. L'objectif est de déterminer la suite la plus probable à partir des données acquises jusque là. Pour les méthodes de reconnaissance citées dans la sous-section 4.4.1, la détection de la manœuvre la plus probable s'accompagne généralement de la trajectoire la plus probable dans la base de données utilisées. La réponse est donc immédiate.

La méthode que nous avons développée pour faire suite à notre MRM se rapproche l'approche utilisée dans [Werling et al., 2010] pour planifier la trajectoire optimale d'un véhicule de sa position actuelle vers un voie définie comme cible. Le mouvement est calculé en déterminant sa composante latérale et sa composante longitudinale dans un repère de Frenet, le long de la ligne centrale de sa voie initiale. Pour chaque composante, un ensemble de trajectoires, modélisées par des polynômes de degré 5, est généré par variation des paramètres définissant l'état final du véhicule puis la meilleure trajectoire est choisie par minimisation d'une fonction de coût. Les deux meilleures composantes sont ensuite combinées pour obtenir la trajectoire planifiée.

Le repère de Frenet joue un rôle central car il permet de conserver la représentation polynomiale des trajectoires même lorsque celles-ci sont fortement courbées. Présentons d'abord quelques principes du repère de Frenet le long d'une ligne.

4.5.1 Repère de Frenet le long d'une ligne

L'étude du mouvement des objets pour une application automobile se fait très souvent dans un repère cartésien, ceci parce que l'orthogonalité des deux dimensions permet, dans bien des cas, de faire une analyse indépendante du mouvement suivant chacune d'elles. Il est de coutume de faire une analyse longitudinale, c'est-à-dire suivant la direction de l'axe du véhicule et une analyse latérale, suivant la direction perpendiculaire, même s'il n'y a pas une parfaite indépendance de ses deux composantes. Puisqu'un véhicule se déplace souvent sur une route, il est opportun de définir un repère cartésien dont l'axe des abscisses correspond à l'axe de la voie de circulation et dont l'axe des ordonnées y est orthogonal. Cette solution est parfaite pour une route rectiligne mais inadaptée à une route courbe. Le repère de Frenet est une alternative intéressante car elle définit un repère mobile dont les axes sont respectivement tangent et normal à la courbe décrite par la voie.

Soit le repère de Frenet le long de la ligne centrale de la voie considérée. La figure 4.4 illustre la trajectoire d'un objet dans le repère de Frenet le long de la ligne centrale de sa voie de circulation.

Soit un point M de la trajectoire. Son projeté orthogonal sur la ligne de Frenet est noté A . Les deux vecteurs unitaires respectivement tangent et normal à la ligne au point A sont notés \vec{T} et \vec{N} . L'origine du repère est un point O appartenant à la ligne et défini arbitrairement. Les coordonnées de M sont notées (s, d) où s est l'abscisse curviligne du point A sur la ligne, c'est-à-dire la distance séparant O et A le long de la ligne et d est la longueur du segment $[AM]$.




Figure 4.4: Trajectoire dans le repère de Frenet

Le calcul de la trajectoire se faisant dans le repère de Frenet, expliquons comment passer de ce repère au repère cartésien et vice-versa.

Détermination des coordonnées (s, d) d'un point M à partir de ses coordonnées (x_M, y_M) dans le repère cartésien

L'équation de la ligne de Frenet est fournie par le module de détection de la route sous la forme $y = f(x)$ (cf équation 4.3).

Considérons le point A de coordonnées (x_a, y_a) avec $y_a = f(x_a)$. s n'est autre que la longueur de l'arc de courbe située entre le point O de coordonnées (x_o, y_o) connues et le point A . Elle s'obtient par intégration des longueurs élémentaires le long de la ligne :

$$s = \int_{x_o}^{x_a} \sqrt{1 + f'(x)^2} dx \tag{4.10}$$

Le paramètre d est la distance signée AP qui si elle est positive est calculée par

$$d = \sqrt{(x_a - x_M)^2 + (y_a - y_M)^2} \quad (4.11)$$

Pour faire ces calculs, il faut connaître x_a . Pour le déterminer, il suffit de remarquer que A est le point de la courbe qui minimise la distance au point P . Un point quelconque de la courbe, d'abscisse x a pour coordonnées $(x, f(x))$. L'expression du carré de sa distance au point P est

$$D^2(x) = (x - x_M)^2 + (f(x) - y_M)^2$$

on a donc

$$x_a = \arg \min_x ((x - x_M)^2 + (f(x) - y_M)^2) \quad (4.12)$$

La résolution analytique des équations 4.12 et 4.10 est faisable si l'expression de la fonction $f(x)$ correspond à une droite ou à un cercle. Dans le cas contraire, le calcul peut être fait numériquement.

La composante longitudinale du mouvement suit la direction du vecteur \vec{T} et sa composante latérale suit le vecteur \vec{N} . Déterminons \vec{T} et \vec{N} pour faire la transformation inverse.

Détermination de \vec{T} et \vec{N}

\vec{T} et \vec{N} sont les vecteurs unitaires respectivement tangent et normal à la courbe au point A . \vec{T} est colinéaire à la tangente :

$$\vec{T} = \left(\frac{1}{\sqrt{1 + f'(x_a)^2}}, \frac{f'(x_a)}{\sqrt{1 + f'(x_a)^2}} \right) \quad (4.13)$$

\vec{N} se déduit de sorte à être orthogonal

$$\vec{N} = \left(\frac{1}{\sqrt{1 + 1/f'(x_a)^2}}, \frac{-1/f'(x_a)}{\sqrt{1 + 1/f'(x_a)^2}} \right) \quad (4.14)$$

Détermination des coordonnées (x_M, y_M) d'un point M à partir de ses coordonnées (s, d) dans le repère de Frenet

Considérons le point A , projeté orthogonal de M sur la courbe et considérons le vecteur normal \vec{N} calculé à l'aide l'équation 4.14. Les coordonnées de M s'obtiennent par

$$\vec{M} = d \cdot \vec{N}$$

La détermination du point A est encore le point clé. Considérons l'équation 4.10. Dans ce contexte, l'inconnue est x_a et tous les autres paramètres sont connus. Soit la fonction $g(x)$ que l'on cherche à annuler :

$$g(x) = s - \int_{x_o}^x \sqrt{1 + f'(t)^2} dt$$

x_a n'est autre que la racine de $g(x)$. Sa détermination peut être faite numériquement si l'expression de $f(x)$ ne permet pas de trouver une solution analytique. L'ordonnée du point A est obtenue par

$$y_a = f(x_a)$$

4.5.2 Prédiction d'un ensemble de trajectoires possibles

Considérons un repère cartésien et un véhicule se déplaçant toujours dans le sens des x positifs, sur une route restiligne, comme montré sur la figure 4.5.

Dans [Takashi et al., 1989] les auteurs ont démontré que la composante longitudinale et la composante latérale du mouvement du véhicule dans ces conditions peuvent chacune être modélisée de façon optimale par un polynôme de degré 5. En effet, un tel polynôme est dérivable au moins trois fois, garantissant ainsi la continuité du jerk (variation de l'accélération) tout au long du mouvement. La connaissance




Figure 4.5: Trajectoire dans un repère cartésien, sur une route droite

des 6 paramètres cinématiques définissant l'état initial et l'état final suivant chaque dimension de permet de définir un polynôme de degré 5 unique pour chaque composante. La combinaison des deux composantes permet de retrouver la trajectoire décrite par le mouvement. Dans notre cas la route n'est pas forcément droite. Ainsi, afin de pouvoir conserver le modèle polynomial nous considérons le repère de Frenet le long de la ligne centrale de la voie actuelle du véhicule. Les trajectoires sont donc d'abord générées dans le repère de Frenet puis converties dans le repère cartésien de départ.

Pour définir une trajectoire de l'ensemble, nous avons besoin de définir, complètement, l'état initial et l'état final associés. Pour la composante latérale nous adoptons les notations suivantes respectivement pour l'état initial et l'état final :

$$D_0 = (d_0, \dot{d}_0, \ddot{d}_0)$$

$$D_1 = (d_1, \dot{d}_1, \ddot{d}_1)$$

et . Pour la composante longitudinale nous avons : $S_0 = (s_0, \dot{s}_0, \ddot{s}_0)$ et $S_1 = (s_1, \dot{s}_1, \ddot{s}_1)$.

Détermination de l'état initial des trajectoires dans la base de Frenet

L'état initial est le même pour toutes les trajectoires générées puisqu'elles ont toutes le même point de départ bien connu. Les paramètres initiaux sont connus dans le repère cartésien grâce au Module de Perception mais ont néanmoins besoin d'être

passés dans la base de Frenet. Le système d'équations 4.15 montre le passage .

$$\begin{cases} d_0 &= d_0^* \\ \dot{d}_0 &= v_0 \sin(\theta_0 - \theta_{\vec{T}_0}) \\ \ddot{d}_0 &= \sqrt{(a_0^2 + \gamma_0 v_0^2)} \sin(\theta_0 - \theta_{\vec{T}_0}) \\ s_0 &= 0 \\ \dot{s}_0 &= v_0 \cos(\theta_0 - \theta_{\vec{T}_0}) \\ \ddot{s}_0 &= \sqrt{(a_0^2 + \gamma_0 v_0^2)} \cos(\theta_0 - \theta_{\vec{T}_0}) \end{cases} \quad (4.15)$$

d_0^* est la distance euclidienne (signée) entre le point (x_0, y_0) et la ligne centrale de la voie (voir équation 4.11), $\theta_{\vec{T}_0}$ est l'orientation du vecteur tangent \vec{T}_0 (voir équation 4.13) représenté dans la figure 4.4. L'abscisse curviligne initiale s_0 est arbitrairement définie égale à zéro. Ce point définit donc l'origine du repère de Frenet. $\gamma_0 v_0^2$ est la valeur de l'accélération normale initiale.

Détermination de l'état final des trajectoires dans la base de Frenet

L'état final de la manœuvre est directement défini dans la base de Frenet, mais nous n'en avons qu'une connaissance partielle. Soit d^* l'écart latéral (mesuré par la caméra) entre la ligne centrale de la voie prévue par l'APV¹ et la ligne centrale de la voie actuelle du véhicule. Éventuellement d^* est nul si la voie prévue correspond à la voie actuelle.

En considérant une accélération longitudinale constante lors de la manœuvre ($a_0 = a_1 = a$) et en supposant qu'à la fin de la manœuvre le véhicule se déplace sur la ligne centrale de la voie prévue, les données connues sur l'état final sont résumées par le système d'équations 4.16.

$$\begin{cases} d_1 &= d^* \\ \dot{d}_1 &= 0 \\ \ddot{d}_1 &= 0 \\ \ddot{s}_1 &= a \end{cases} \quad (4.16)$$

A partir de l'ensemble de données de roulage présentées dans la section 4.8.1 nous admettons que les canoniques citées ont une durée de moins de 6 secondes en situation nominale. Nous supposons donc que l'instant t_1 de fin de la manœuvre sera dans l'intervalle $]0, 6s]$. Cet intervalle peut être étendu (ou restreint) si nécessaire. Cela n'affecte pas la méthode proposée ici mais a un effet sur le temps d'exécution.

1. Algorithme de Prédiction de Voie

L'intervalle ainsi défini est échantillonné avec un pas de temps T_e . En considérant chaque instant t_1 échantillonné, nous connaissons la valeur de \dot{s}_1 puisque l'accélération longitudinale est constante et qu'à la fin de la manœuvre le véhicule se déplace parallèlement à la ligne centrale. On a :

$$\dot{s}_1 = v_0 + a \cdot t_1$$

Par contre nous n'avons toujours aucune connaissance sur la distance longitudinale s_1 parcourue.

Chaque instant t_1 échantillonné sera utilisé pour générer une trajectoire unique et nous obtiendrons donc un ensemble fini de trajectoires.

Calcul de la composante latérale des trajectoires

Comme il est possible d'établir 6 relations latérales entre l'origine et la fin, la composante latérale des trajectoires peut être décrite par une équation du cinquième degré de la forme :

$$d(t) = c_5 t^5 + c_4 t^4 + c_3 t^3 + c_2 t^2 + c_1 t + c_0$$

où $c_i, i = 1..5$ sont constantes.

Connaissant les paramètres aux instants t_0 et t_1 ainsi que l'expression des deux premières dérivées de $d(t)$, les coefficients du polynôme sont obtenus en résolvant le système d'équations 4.17

$$\begin{bmatrix} t_0^5 & t_0^4 & t_0^3 & t_0^2 & t_0^1 & 1 \\ t_1^5 & t_1^4 & t_1^3 & t_1^2 & t_1^1 & 1 \\ 5t_0^4 & 4t_0^3 & 3t_0^2 & 2t_0^1 & 1 & 0 \\ 5t_1^4 & 4t_1^3 & 3t_1^2 & 2t_1^1 & 1 & 0 \\ 20t_0^3 & 12t_0^2 & 6t_0^1 & 2 & 0 & 0 \\ 20t_1^3 & 12t_1^2 & 6t_1^1 & 2 & 0 & 0 \end{bmatrix} \cdot \begin{bmatrix} c_5 \\ c_4 \\ c_3 \\ c_2 \\ c_1 \\ c_0 \end{bmatrix} = \begin{bmatrix} d_0 \\ d_1 \\ \dot{d}_0 \\ \dot{d}_1 \\ \ddot{d}_0 \\ \ddot{d}_1 \end{bmatrix} \quad (4.17)$$

Calcul de la composante longitudinale des trajectoires

Dans la dimension longitudinale, nous avons vu qu'il reste une inconnue (s) pour définir l'état final. Nous perdons donc un degré de liberté et la composante longitudinale sera modélisée par un polynôme du quatrième degré de la forme :

$$s(t) = c_4 t^4 + c_3 t^3 + c_2 t^2 + c_1 t + c_0$$

La continuité du jerk est conservée puisque le polynôme est au moins 3 fois dérivable. Les coefficients sont déterminés en résolvant le système d'équations

$$\begin{bmatrix} t_0^4 & t_0^3 & t_0^2 & t_0^1 & 1 \\ 4t_0^3 & 3t_0^2 & 2t_0^1 & 1 & 0 \\ 4t_1^3 & 3t_1^2 & 2t_1^1 & 1 & 0 \\ 12t_0^2 & 6t_0^1 & 2 & 0 & 0 \\ 12t_1^2 & 6t_1^1 & 2 & 0 & 0 \end{bmatrix} \cdot \begin{bmatrix} c_4 \\ c_3 \\ c_2 \\ c_1 \\ c_0 \end{bmatrix} = \begin{bmatrix} s_0 \\ \dot{s}_0 \\ \dot{s}_1 \\ \ddot{s}_0 \\ \ddot{s}_1 \end{bmatrix} \quad (4.18)$$

De la base de Frenet au repère cartésien

$d(t)$ et $s(t)$ donnent la représentation paramétrique de chaque trajectoire en fonction du temps dans la base de Frenet. L'objectif est maintenant de déterminer la représentation paramétrique dans le repère cartésien $\{x(t), y(t)\}$. Nous avons vu comment faire la conversion des coordonnées d'un point défini dans la base de Frenet vers le repère cartésien. Il n'est pas possible de trouver une formule de conversion permettant d'obtenir l'expression de la trajectoire $\{x(t), y(t)\}$ sous forme continue. La méthode que nous proposons d'utiliser consiste à discrétiser la trajectoire $\{d(t), s(t)\}$ dans la base de Frenet, puis à convertir chacun des points vers la base cartésienne. Chaque trajectoire prédite est donc un ensemble de points formant une polyligne

$$M^K = \{M_0, M_1, \dots, M_k, \dots, M_K\}$$

correspondant à un ensemble d'instant

$$T^K = \{t_0, t_1, \dots, t_k, \dots, t_K\}$$

échantillonnés sur l'intervalle de prédiction avec une période plus petite ou égale à la période du Système de Perception.

4.5.3 Sélection de la meilleure trajectoire

Admettons qu'un conducteur moyen cherche à réduire la durée de ses manœuvres tout en essayant de maximiser le confort dans l'habitacle. Il cherche aussi à minimiser les oscillations tout au long de la manœuvre et à ne pas aller au delà de la ligne centrale de la voie visée. Les trajectoires générées par la méthode décrite ne présentent pas d'oscillation mais peuvent avoir des dépassements (*overshoots*) suivant l'état initial (voir Fig. 4.6).

Puisqu'il n'y a pas d'oscillation et que l'accélération longitudinale est supposée constante tout au long d'une manœuvre, le confort dans l'habitacle peut être quantifié par l'accélération normale subie. D'autre part, on remarque que les manœuvres




Figure 4.6: Trajectory generation and selection.

ayant des overshoots sont finalement les plus longues. On définit donc la fonction de coût suivante :

$$C = k_a \cdot \max(|a_N(t)|) + k_t \cdot t_1 \quad (4.19)$$

$a_N(t)$ est la norme accélération normale du véhicule pendant la manœuvre et k_a et k_t sont des coefficients de pondération positifs qui servent à définir le comportement voulu pour la fonction de coût. Cette fonction pénalise donc les trajectoires ayant une longue durée et celles ayant des overshoots. D'autre part, elle pénalise les trajectoires ayant des pics importants au niveau de l'accélération normale. Au lieu de considérer ces pics, d'autres auteurs [Werling et al., 2010] proposent d'en faire une moyenne sur toute la durée de la manœuvre.

4.6 Combinaison des deux trajectoires prédites

La trajectoire prédite en utilisant un modèle général de mouvement (notée T_{mdl}) est généralement assez précise sur un court horizon de temps. A plus longue échéance et sans correction, l'erreur de modèle devient importante, surtout quand les entrées de commandes du véhicule varient. La trajectoire prédite à partir de la reconnaissance de manœuvre (notée T_{man}) permet de choisir un modèle de trajectoire mieux adapté à la manœuvre reconnue. Comme mentionné précédemment, la reconnaissance de manœuvre peut être sujette à un certain retard de détection. L'objectif recherché en combinant les deux trajectoires est de d'une part de profiter de la bonne précision de T_{mdl} pour les premiers instants de prédiction et de s'affranchir autant que possible du retard de détection de la manœuvre en cours. Ainsi, nous proposons de calculer la trajectoire finale prédite (notée T_{fin}) par la formule de l'équation 4.20.

$$T_{fin}(t) = f(t) \cdot T_{mdl}(t) + (1 - f(t)) \cdot T_{man}(t) \quad (4.20)$$




Figure 4.7: Fonction de pondération $f(t)$

où $f(t)$ est une spline cubique illustrée par la figure 4.7.

Pour les prédictions à court terme, le résultat est très proche de T_{mdl} ; au fur et à mesure que l'horizon de prédiction croît, le résultat se rapproche de T_{man} . Les points d'inflexion de la courbes sont des paramètres réglables afin de varier l'influence de chacune des deux trajectoires pré-calculée. Nous proposons une discussion sur la variation de la fonction de pondération lors de l'analyse des résultats sur la prédiction de trajectoire (4.8.1 page 113).

4.7 Calcul de risque de collision

4.7.1 Notion de risque de collision

Si les trajectoires prédites étaient absolument certaines et si la forme géométrique des objets était parfaitement connue, l'éventualité d'une collision serait une valeur parfaitement binaire. En effet, il suffirait de vérifier sur l'horizon de prédiction, s'il existe au moins un instant où l'espace occupé par l'égo-véhicule recouvre celui d'un obstacle donné. On saurait donc de façon certaine, s'il y aura une collision et, si oui, à quel moment précis (à une période d'échantillonnage près). Mais ce n'est pas le cas en pratique puisque, d'une part, les méthodes de prédiction de trajectoires ne donnent qu'une approximation de la future trajectoire et que, d'autre part, elles se basent sur des estimations d'état qui sont initialement sujettes à une incertitude ; les positions prédites sont par conséquent aussi incertaines. C'est pourquoi nous devons évaluer un risque de collision qui est une valeur stochastique.

La notion de risque de collision peut revêtir plusieurs aspects. On peut, par exemple, s'intéresser à un risque global de collision par rapport à tous les objets détectés, à la fois, ou bien chercher à évaluer individuellement le risque de collision pour chaque objet. D'autre part, de façon communément admise, le risque de collision est le produit de la probabilité de la collision annoncée et de sa gravité. La gravité dépend

en particulier de la nature de l'objet ou des objets impliqués (piéton, deux-roues, voiture, poids-lourd etc.). Par exemple, on admet que la gravité est plus importante s'il s'agit d'une collision avec un piéton ou un cycliste que s'il s'agissait d'un autre véhicule. D'un point de vue ADAS, ce facteur sert surtout à pondérer les seuils qui définissent les niveaux d'alerte ou éventuellement les actions à effectuer, ce, en vue de préserver au maximum l'intégrité physique des personnes.

Pour nos travaux, nous considérons qu'une collision implique l'égo-véhicule et un seul objet à la fois, ceci parce que l'objectif est de déterminer, dans les cas critiques, une manœuvre permettant d'éviter un objet particulier sans, bien sûr, causer d'autres collisions. La définition de la gravité peut très vite impliquer des notions liées à l'éthique et ne fait pas partie des objectifs de cette thèse. L'évaluation de la gravité d'une collision n'est pas prise en compte dans nos travaux. Nous nous concentrons donc sur l'évaluation de la probabilité de collision.

4.7.2 État de l'art

Dans [Laugier et al., 2011], chaque trajectoire prédite est considérée comme un Processus Gaussien [Breton, 2006] puis un grand nombre de tirages aléatoires sont réalisés pour obtenir plusieurs trajectoires aléatoires de chaque objet (l'égo-véhicule et un véhicule considéré). Ensuite, le pourcentage du nombre de trajectoires de l'égo-véhicule menant à une collision avec l'objet, par rapport au nombre total de tirages effectués est calculé et considéré comme le risque de collision. Cette opération correspond à simulation de Monte-Carlo. Ici on évalue la probabilité de collision globale sur toute la durée de prédiction sans faire une estimation du temps-avant-collision (TTC¹), ce qui ne permet pas d'envisager des actions particulières par rapport à un instant butoir.

Dans [Berthelot et al., 2011], les auteurs se servent des trajectoires prédites pour définir la fonction $d_e(t)$ représentant la distance entre les deux objets au cours du temps. Ensuite, ils déterminent, si elle existe, la plus petite racine positive de cette fonction qui correspond donc à une estimation du TTC. En supposant ensuite que les variances des poses prédites sont constantes tout au long des trajectoires prédites et égales à leurs valeurs initiales respectives (estimées à l'instant courant), ils estiment la probabilité que les objets soient en collision à cet instant. La méthode d'estimation mise en œuvre est ici aussi une simulation de Monte-Carlo. Elle consiste à tirer aléatoirement un grand nombre de positions possibles pour chaque objet, suivant une distribution gaussienne dont la moyenne est la position estimée de l'objet à l'instant futur TTC et dont la variance est celle de la position de l'objet à l'instant courant. Cette méthode de calcul du risque de collision permet d'approximer la probabilité de collision pour un TTC bien précis, obtenu en calculant de façon déterministe l'instant où la fonction de distance $d_e(t)$ s'annule. Or les trajectoires considérées peuvent être fausses et le TTC réel peut être différent et potentiellement

1. Time-To-Collision




Figure 4.8: (a) En considérant une variance constante, la probabilité de collision peut être sous estimée. Ici, elle apparaît nulle. (b) Lorsque la variance croît au fil du temps, on voit que le risque de collision n’est pas nul.

plus faible. Une autre faiblesse de cette méthode est qu’en réalité la variance des poses prédites n’est pas constante, elle croît avec le temps, car sans mesures pour faire des corrections qui corrigent le bruit de modèle, on obtient une dérive qui croît. Cela conduit à une surestimation de la probabilité de collision si les fenêtres décrites par les variances respectives des deux objets s’intersectent et une sous estimation sinon (voir figure 4.8).

Dans [Lambert et al., 2008], les auteurs proposent une méthode de calcul de la probabilité que deux objets soient en collision à un instant précis, connaissant leurs poses respectives à cet instant et les variances associées. Si les objets sont ponctuels, la probabilité P_{coll} qu’ils soient en collision à cet instant, s’exprime par l’intégrale du produit de leur deux fonctions de densité de probabilité, p_1 et p_2 , dans le plan considéré :

$$P_{coll} = \iint_{\mathbb{R}^2} p_1(\xi) p_2(\xi) dx dy \quad (4.21)$$

Une interprétation physique peut être énoncée comme suit : lorsque les objets sont bien assez précisément localisés et suffisamment éloignés, la zone de recouvrement des deux densités de probabilité est petite et la probabilité de collision est faible. S’ils sont plutôt proches, le recouvrement est grand et la probabilité de collision est importante. Si les objets sont très imprécisément localisés, la zone de recouvrement est grande mais du fait que les densités sont assez “plates”, P_{coll} est petit.

Si les distributions sont gaussiennes et si on note les positions respectives des deux objets ξ_1 et ξ_2 , à un instant t , dans le repère cartésien, avec leurs matrices de

covariances Σ_1 et Σ_2 , on a

$$p_i(\xi) = \frac{1}{2\pi\sqrt{|\Sigma_i|}} e^{-\frac{1}{2}((\xi-\xi_i)^T P_i^{-1}(\xi-\xi_i))}, |i = \{1, 2\}$$

où $\xi = [x, y]^T$ est un vecteur position.

Dans ce cas gaussien on peut déterminer une expression analytique de P_{coll} . Mais si les objets occupent respectivement les surfaces non nulles \mathcal{S}_1 et \mathcal{S}_2 , la probabilité de collision s'obtient par :

$$P_{coll} = \int_D p_1(\xi) p_2(\xi) dx_1 dy_1 dx_2 dy_2 \quad (4.22)$$

avec

$$D = \{(x_1, y_1, x_2, y_2) \in \mathbb{R}^4 | \mathcal{S}_1 \cap \mathcal{S}_2 \neq \emptyset\}$$

Le calcul analytique de P_{coll} n'est pas possible dans ce cas et les auteurs l'estime par simulation de Monte-Carlo. Elle consiste à faire un grand nombre de tirages aléatoires pour les positions des deux objets à partir de moments statistiques estimés. Ensuite, pour l'ensemble des paires de tirages effectués, on détermine les surfaces \mathcal{S}_1 et \mathcal{S}_2 correspondant à chaque objet et on fait un test d'intersection. Enfin, le ratio du nombre de cas où \mathcal{S}_1 et \mathcal{S}_2 s'intersectent, sur le nombre total de paires considérées représente la probabilité de collision. La probabilité de collision ainsi obtenue est valable uniquement pour l'instant considéré et ne rend pas compte du risque de collision sur toute la trajectoire prédite de l'égo-véhicule.

4.7.3 Méthode proposée

D'un point de vue ADAS, l'objectif du calcul de risque de collision est de permettre la définition de plusieurs niveaux d'alerte correspondant chacun à des actions spécifiques. Par exemple, le niveau le plus faible peut correspondre à des bips sonores et le niveau le plus critique consiste à prendre le contrôle du véhicule pour éviter l'accident. Pour ce faire, la méthode que nous proposons consiste à considérer un ensemble d'instantanés échantillonnés $T^K = \{t_0, \dots, t_k, \dots, t_K\}$, sur l'intervalle de prédiction considéré. Ensuite, pour chacun des $t_k \in T^K$ nous évaluons la probabilité de collision. Il n'y a donc pas une estimation, à proprement parler, du TTC mais chaque instant futur est considéré comme un TTC potentiel et on évalue la probabilité de collision pour cet instant. La période d'échantillonnage ici ne dépend pas des capteurs, elle est librement fixée lors de la prédiction de trajectoire et définie aussi petite que possible sans empêcher un traitement en temps-réel. On peut

ainsi définir plusieurs niveaux d'alerte correspondant chacun à un double seuillage TTC/Probabilité de collision. Par exemple, si la probabilité de collision est supérieure à un seuil s_{Pr} pour un TTC inférieur à un seuil s_{TTC} alors, on peut générer une alerte. Les valeurs des seuils définissent la sensibilité du système et sont considérés comme des paramètres réglables. Remarquons qu'il arrive parfois dans la littérature que le TTC désigne le temps nécessaire à un véhicule suiveur pour rattraper un véhicule le précédant, suivant une ligne droite. Dans notre contexte, c'est le temps nécessaire suivant la trajectoire prédite pour chaque objet.

La méthode que nous proposons pour évaluer le risque de collision à un instant repose également sur une simulation de Monte-Carlo. Les grandes étapes sont les suivantes :

1. Propager l'incertitude initiale sur chaque future pose échantillonnée,
2. Pour chaque pose future de l'égo-véhicule, évaluer la probabilité de collision avec chacun des autres mobiles au même instant,
3. Fournir pour chaque mobile, les paires TTC/Probabilité de collision le long de la prédiction.

Propagation de l'incertitude

Soit $\xi^K = \{\xi_0, \xi_1, \dots, \xi_k, \dots, \xi_K\}$ l'ensemble des poses prédites $\xi = [x, y, \theta]^T$ pour un mobile (l'égo-véhicule ou un objet pisté) sur l'horizon de prédiction T^K échantillonné selon une période de temps T_e . ξ_0 étant la pose estimée de l'objet au moment de la prédiction de trajectoire et sa matrice de covariance Σ_0 étant connue, l'objectif est de retrouver la matrice de covariance Σ_k associée à chaque pose future.

Admettons pour l'instant que la prédiction de trajectoire respecte un modèle connu tel que la pose ξ_{k+1} soit définie en fonction de la pose ξ_k par :

$$\xi_{k+1} = f_k(\xi_k) + \alpha$$

où α représente l'erreur de modélisation.

La matrice de covariance de ξ_{k+1} est alors calculée par linéarisation tangente :

$$\Sigma_{k+1} = J \cdot \Sigma_k \cdot J^T + Q$$

où Q est la matrice de covariance de α et

$$J = \frac{\partial f_k}{\partial \xi}(\xi_k)$$

Selon la méthode de prédiction de trajectoire utilisée, il n'est pas toujours possible d'avoir la forme explicite de la fonction f_k . C'est ce qui se passe dans notre cas puisque nous n'obtenons pas une fonction explicite définissant la trajectoire prédite mais plutôt un ensemble discret de positions prédites. Il est alors impossible de calculer la jacobienne J et donc d'appliquer la méthode précédente.

Nous proposons ci-après une méthode de propagation de l'incertitude qui fonctionne de façon séquentielle en considérant que la trajectoire prédite est localement linéaire entre deux échantillons. Pour ce faire, considérons un vecteur d'état augmenté, noté \mathbb{X} , et sa matrice de covariance, notée \mathbb{P} tels que pour un instant t_k donné on a

$$\mathbb{X}_k = \begin{bmatrix} \xi_k \\ \dot{\xi}_k \end{bmatrix} = \begin{bmatrix} x_k \\ y_k \\ \theta_k \\ v_{x,k} \\ v_{y,k} \\ \omega_k \end{bmatrix}$$

Initialement, \mathbb{X}_0 et \mathbb{P}_0 sont connus car déduits de l'estimation d'état courante et de sa matrice de covariance.

Les vitesses $v_{x,k}$, $v_{y,k}$ et ω_k peuvent être estimées par la méthode d'Euler (différence première). Comme la période d'échantillonnage T_e et tous les points de la trajectoire sont connus, on peut calculer la vitesse avec un point en avance :

$$v_{x,k} = \frac{x_{k+1} - x_k}{T_e}$$

Si on intègre le long de la trajectoire avec $x_{k+1} = x_k + T_e \cdot v_{x,k}$ et si on développe cette expression, on vérifie qu'on a bien $x_{k+1} = x_{k+1}$. Ainsi en partant de x_0 , on retrouve exactement tous les points de la trajectoire calculée.

Pour propager l'incertitude, il faut prendre en compte l'incertitude sur la vitesse et il faut donc avoir un modèle pour toutes les composantes du vecteur \mathbb{X}_k . Nous proposons d'approximer le mouvement élémentaire entre 2 échantillons par un mouvement linéaire à vitesse constante, soit pour la composante en x :

$$v_{x,k+1} = v_{x,k}$$

Cette expression est effectivement approximative le long d'une trajectoire courbe puisque la vitesse varie.

On propose donc expliciter une erreur de modèle α .

Ainsi, on peut écrire

$$\mathbb{X}_{k+1} = A_k \mathbb{X}_k + \alpha$$




Figure 4.9: Illustration de la propagation d'incertitude le long de la trajectoire prédite. Les ellipses représentent l'incertitude, la courbe verte représente la trajectoire discrète prédite et la courbe bleue représente la trajectoire réelle.

où A_k est la matrice de transition linéaire *locale* :

$$A_k = \begin{bmatrix} 1 & 0 & 0 & T_e & 0 & 0 \\ 0 & 1 & 0 & 0 & T_e & 0 \\ 0 & 0 & 1 & 0 & 0 & T_e \\ 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \quad (4.23)$$

La matrice de covariance Q du bruit de modèle α est choisie constante avec uniquement les trois derniers termes de diagonale non nuls.

On peut alors propager l'incertitude par

$$\mathbb{P}_{k+1} = A_k \cdot \mathbb{P}_k \cdot A_k^T + Q \quad (4.24)$$

La matrice Σ_{k+1} recherchée est le bloc supérieur gauche de \mathbb{P}_{k+1} .

La figure 4.9 montre un exemple de propagation de l'incertitude le long d'une trajectoire prédite, pour un état à 4 dimensions (sans les paramètres d'orientation).

Pour cet exemple, on a : $\mathbb{P}_0 = \begin{bmatrix} 1 & 0.81 & 0 & 0 \\ 0.81 & 1 & 0 & 0 \\ 0 & 0 & 1 & 0.64 \\ 0 & 0.64 & 0 & 1 \end{bmatrix}$ et $Q = \begin{bmatrix} 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \end{bmatrix}$

Calcul de la probabilité de collision par simulation de Monte Carlo

Pour déterminer la collision entre 2 véhicules à un instant donné, il faut voir si leurs rectangles englobants s'intersectent. Pour cela, il faut connaître pour chaque rectangle, la position de son centre, qui correspond à la position estimée du véhicule, son orientation, qui est le cap du véhicule et ses dimensions (Fig. 4.10).




Figure 4.10: Détection de collision entre deux véhicules

L'**Algorithme 4.2** permet de détecter s'il y a une intersection entre deux rectangles. La fonction *CotésRectangle* décrite par l'**Algorithme 4.3** permet de définir dans un repère cartésien les quatre cotés d'un rectangle dont on connaît le centre et l'orientation. La fonction *IntersectionCotés* permet de tester l'intersection entre deux segments quelconques dans un repère cartésien. L'algorithme de Bentley-Ottmann [Bentley and Ottmann, 1979] permet de déterminer les éventuelles k intersections pour un ensemble de n segments, avec une complexité en $O((n + k) \log n)$.

Algorithme 4.2 Détection de collision entre 2 rectangles

```

Fonction DétecteCollision( $R_1, R_2$ )
     $\{C_{1,1}, C_{1,2}, C_{1,3}, C_{1,4}\} \leftarrow \text{CotésRectangle}(R_1)$ 
     $\{C_{2,1}, C_{2,2}, C_{2,3}, C_{2,4}\} \leftarrow \text{CotésRectangle}(R_2)$ 
    Pour i de 1 à 4
        Pour j de 1 à 4
            Si IntersectionCotés( $C_{1,i}, C_{2,j}$ )=vrai
                Retourne vrai
            Fin Si
        Fin Pour
    Fin Pour
    Retourne faux
Fin

```

Algorithme 4.3 Détermination des 4 cotés d'un rectangleFonction CotésRectangle(R)#Un rectangle est représenté par 5 paramètres $R = \{x, y, \theta, l, L\}$ #Les 4 sommets sont S_1, S_2, S_3 et S_4 avec $S_i = \begin{bmatrix} x_i \\ y_i \end{bmatrix}_{i=1..4}$ #Les 4 cotés sont C_1, C_2, C_3 et C_4

$$M \leftarrow \begin{bmatrix} \cos\theta & -\sin\theta \\ \sin\theta & \cos\theta \end{bmatrix}$$

$$S_1 \leftarrow M \cdot \begin{bmatrix} L/2 \\ l/2 \end{bmatrix} + \begin{bmatrix} x \\ y \end{bmatrix}$$

$$S_2 \leftarrow M \cdot \begin{bmatrix} -L/2 \\ l/2 \end{bmatrix} + \begin{bmatrix} x \\ y \end{bmatrix}$$

$$S_3 \leftarrow M \cdot \begin{bmatrix} -L/2 \\ -l/2 \end{bmatrix} + \begin{bmatrix} x \\ y \end{bmatrix}$$

$$S_4 \leftarrow M \cdot \begin{bmatrix} L/2 \\ -l/2 \end{bmatrix} + \begin{bmatrix} x \\ y \end{bmatrix}$$

$$C_1 \leftarrow (S_1, S_2)$$

$$C_2 \leftarrow (S_2, S_3)$$

$$C_3 \leftarrow (S_3, S_4)$$

$$C_4 \leftarrow (S_4, S_1)$$

Retourne C_1, C_2, C_3, C_4

Fin

Le cas particulier où un rectangle se retrouve à l'intérieur de l'autre est ignoré car nous supposons que la collision aura été détectée avant. Dans le cas où les dimensions des véhicules sont inconnues, on considère des cercles englobants de diamètre $D = 3.5m$. Il y a une intersection si la distance géométrique entre les centres des cercles est inférieure à D .

A partir de ce test d'intersection, un risque de collision est calculé pour chaque instant échantillonné. La méthode de calcul repose sur les principes de simulation évoqués précédemment. Elle est explicitée par l'**Algorithme 4.4** qui reçoit en argument les moments statistiques estimés des deux mobiles et le nombre de tirages à effectuer. La fonction *random* effectue un tirage aléatoire suivant une distribution gaussienne dont les paramètres sont en argument. La fonction *DetecteCollision* est celle décrite dans l'**Algorithme 4.2**.

Algorithme 4.4 Calcul du risque de collision entre 2 véhicules a et b

Fonction CalculProbabiliteCollision(X_a, P_a, X_b, P_b, N)

```

 $P_{coll} \leftarrow 0$ 
Pour  $i \leftarrow 1$  à  $N$ 
     $X_a^i \leftarrow \text{random}(X_a, P_a)$ 
     $X_b^j \leftarrow \text{random}(X_b, P_b)$ 
    Si DetecteCollision( $X_a^i, X_b^j$ )
         $P_{coll} \leftarrow P_{coll} + 1$ 
    Fin Si
Fin Pour
 $P_{coll} \leftarrow \frac{P_{coll}}{N}$ 
Retourne  $P_{coll}$ 

```

4.8 Résultats d'expérimentation et analyses

4.8.1 Reconnaissance de manœuvre et prédiction de trajectoire

Description de l'expérience

Pour évaluer les méthodes de reconnaissance de manœuvre et de prédiction de trajectoire respectivement proposées dans les sections 4.4 et 4.5, nous avons considéré un jeu de trajectoires pré-enregistrées. L'expérimentation ayant donné lieu à ces enregistrements est la suivante : un véhicule expérimental équipé d'un dispositif GPS est utilisé. On demande successivement à 8 conducteurs lambda d'effectuer des changements de voie à gauche ou à droite dès qu'il le peuvent, sur une chaussée rectiligne. Il s'agit d'une situation de conduite normale et la vitesse moyenne de roulage est de 80km/h. Pendant les roulages, les positions GPS sont sauvegardées puis converties dans un repère cartésien fixe. L'expérience est décrite plus en détails dans [Yao et al., 2012]. Le papier décrit également une méthode automatique permettant d'extraire les parties de trajectoire correspondant à des changements de voie. Ces trajectoires de changement de voies sont ensuite alignées pour avoir le même point de départ. La figure 4.11 montre les 236 trajectoires ainsi obtenues. Notons que le système de location par GPS utilisé à un écart-type d'environ 2m et que la largeur des voies est d'environ 3.5m.

Comme on peut le remarquer l'extraction automatique des trajectoires de changement de voie commet des erreurs mais la majorité des trajectoires correspond bien à des changements de voie. Ainsi, nous avons dénombré 91 changements de voie à droite (RLC¹), 119 changements de voie à gauche (LLC²) et 24 autres trajectoires

1. Right Lane Change
2. Left Lane Change




Figure 4.11: Tracés des 236 trajectoires de changement de voies enregistrées

qui ne sont classées ni RLC ni LLC. Ces dernières ne sont pas prises en compte dans notre analyse. Puisque nous n'avons que des mesures de position et la vitesse moyenne des roulages, nous avons appliqué un filtre de Kalman aux données pour obtenir une estimation de la position, du cap, de la vitesse linéaire et de l'accélération tangentielle du véhicule pour chaque échantillon de données, avec leurs variances respectives.

Évaluation de la reconnaissance de manœuvre

L'objectif est de noter si la bonne manœuvre de changement de voie est reconnue avant que le véhicule ne se retrouve effectivement sur sa nouvelle voie et, si oui, à quel moment par rapport au point de départ et à quel écart latéral par rapport à l'axe de la voie.

On note préalablement pour chaque trajectoire le moment où le véhicule a effectivement changé de voie. Cette vérité terrain est obtenue à partir de la connaissance des limites de chaque voie dans le repère considéré et des positions successives enregistrées.

Ensuite, l'algorithme proposé est itérativement exécuté avec les estimations du filtre de Kalman et on note l'instant où le résultat fourni est différent de la voie initiale de façon stable. En effet, à cause des hésitations de la part du conducteur qui induisent parfois des zigzags dans la voie, il peut y avoir des prédictions qui alternent entre deux voies, au voisinage du seuil fixé.

Les valeurs d'écart-types utilisés pour la ligne centrale de la voie sont : $\sigma_{d_l} = \sigma_{d_r} = 0.5m$, $\sigma_{\theta} = 5^\circ$, $\sigma_{\gamma} = 0.05m^{-1}$. Nous avons fixé le seuil à 2. Ensuite nous avons calculé les moyennes des valeurs obtenues en résultat. Le tableau 4.1 montre le bilan.

	LLC	RLC
Détection	100%	100%
Temps moyen de détection	1.15s	1.09
Écart latéral moyen à la détection	0.3m	0.33m

Table 4.1: Détection de changement de voie avec le temps moyen de détection et l'écart moyen de détection après le début de la manœuvre

Les changements de voie ont été détectés à 100% avant que le changement ne soit effectif. Le temps moyen de détection est d'environ 1s. Cette durée est très raisonnable en comparaison de la durée moyenne d'une manœuvre complète de changement de voie (de l'ordre de 4s). D'autre part, on peut remarquer que l'écart moyen de détection n'est que de 30cm environ. Il est à noter que les conducteurs ont en majorité effectué des changements de voie plutôt doux, c'est-à-dire qu'ils ont quitté lentement leur voie initiale. Pour la trajectoire la plus agressive, le temps de détection est de 0.4s et l'écart latéral correspondant est de 0.25m.

Évaluation de la prédiction de trajectoire

Connaissant les vraies trajectoires de changement de voie, l'objectif est d'estimer la précision des trajectoires prédites, à différents horizons temporels : $[0s, 1s[$, $[1s, 2s[$, $[2s, 3s[$ et $[3s, 4s[$. Nous considérons donc des prédictions de 4s au maximum. Pour chaque trajectoire enregistrée, l'algorithme de prédiction de trajectoire a été exécuté pour chacun des instants échantillonnés. Les figures 4.12 et 4.13 montrent deux exemples de résultats obtenus.

A chaque prédiction effectuée, nous notons les distances euclidiennes entre les positions futures restantes de la trajectoire enregistrée et les positions futures correspondant aux mêmes instants sur la trajectoire prédite. Les distances obtenues sont classées en 4 catégories correspondant à 4 horizons de prédiction définis (de 1 seconde à 4 secondes). Ensuite, nous faisons la moyenne des erreurs de prédiction pour chaque horizon de prédiction et ce, pour l'ensemble des trajectoires pré-enregistrées. Puisque la détection des changements de voie nécessite quelques centaines de millisecondes, tant que la détection n'est pas réalisée, il n'est pas souhaitable d'évaluer le mécanisme de prédiction de trajectoire. Ainsi, nous ne considérons dans cette partie de l'étude que les prédictions faites après la détection du changement de voie. Afin de comparer la prédiction basée sur un modèle de mouvement (T_{mdl}), la prédiction basée sur la reconnaissance de manœuvre (T_{man}) et la trajectoire obtenue en combinant les deux (T_{fin}), nous avons effectué l'opération décrite pour chaque type de prédiction indépendamment. Les résultats obtenus sont montrés dans le tableau 4.2.

L'erreur moyenne de prédiction pour T_{mdl} est très faible pour les prédictions à court terme mais augmente de façon exponentielle avec le temps. La précision de T_{man}

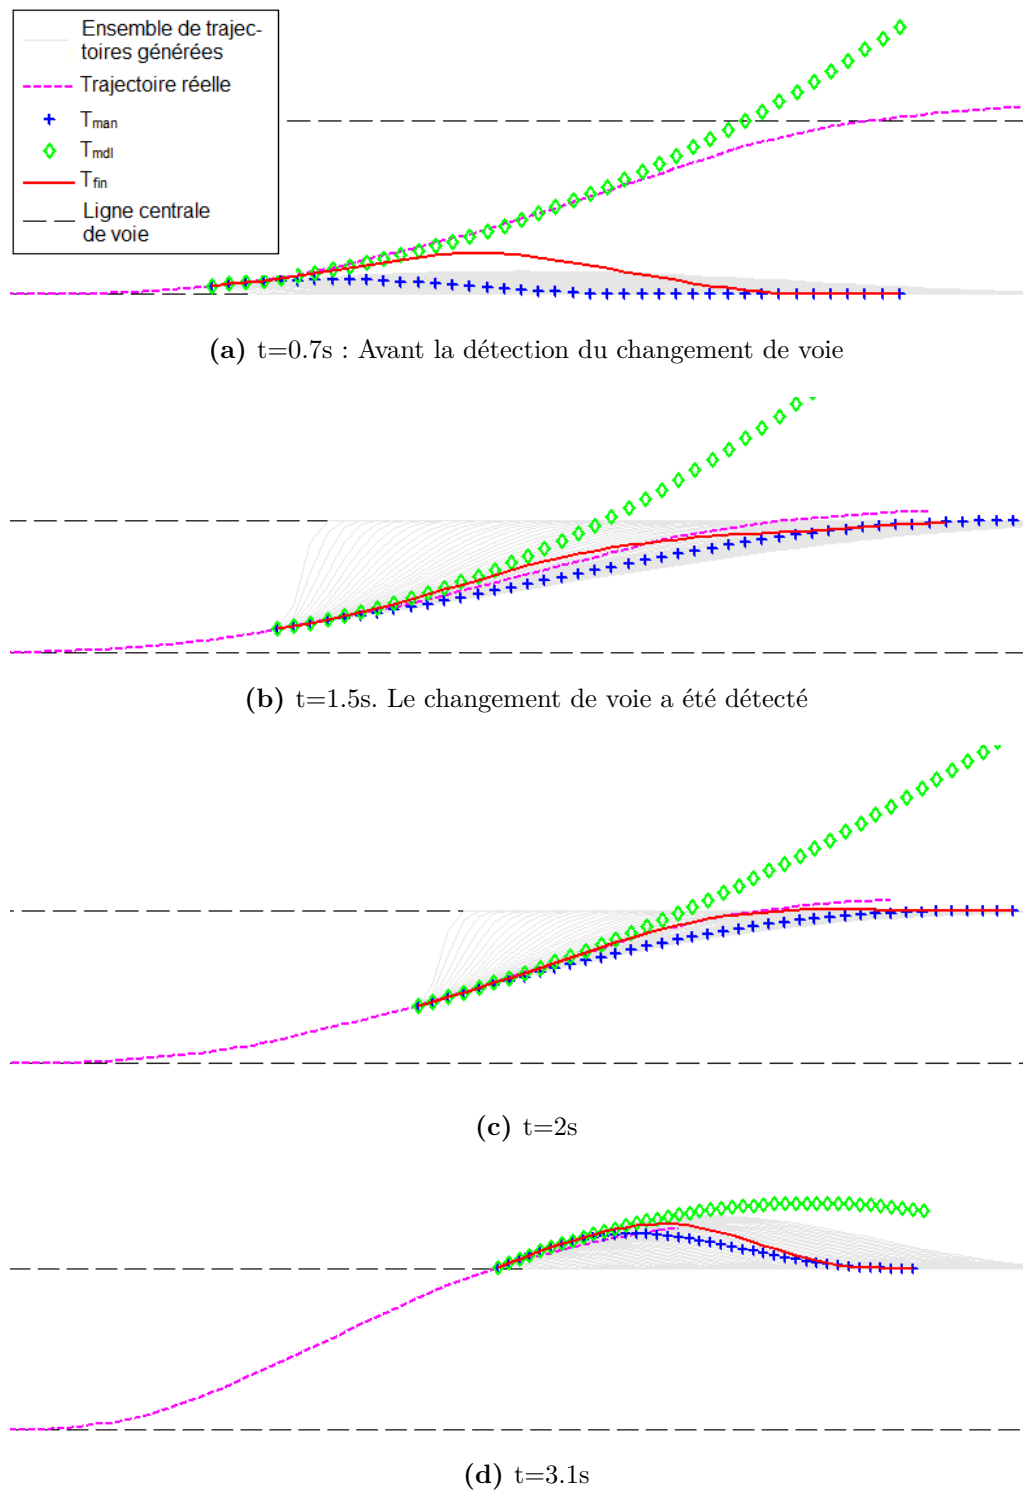


Figure 4.12: Exemple de prédictions de trajectoire à différents instants lors d'un changement de voie à gauche.




Figure 4.13: Exemple de prédictions de trajectoire à différents instants lors d'un changement de voie à droite

	$[0s, 1s[$	$[1s, 2s[$	$[2s, 3s[$	$[3s, 4s[$
T_{mdl}	0.1m	0.49m	2.3m	4.31m
T_{man}	0.15m	0.2m	0.33m	0.45m
T_{fin}	0.09m	0.17m	0.28m	0.45m

Table 4.2: Erreurs moyennes de chaque type de prédiction

diminue aussi avec le temps mais de façon nettement moins importante. Les faibles valeurs d'erreur montrent que T_{man} est déjà très proche de la trajectoire future réelle sur tous les horizons temporels. Pour T_{fin} , dans les intervalles $[0s, 1s[$ et $[3s, 4s[$ les erreurs moyennes sont à peu près identiques à celles de T_{mdl} et T_{man} respectivement. Cela est logiquement dû à la fonction de pondération dans l'équation 4.20. Dans les intervalles $[1s, 2s[$ et $[2s, 3s[$, il est à noter que la précision de T_{fin} est meilleure que celles de T_{mdl} et T_{man} , ce qui signifie que la trajectoire réelle est très souvent entre les deux prédictions (voir figures 4.12 et 4.13). D'un point de vue global, on conclut donc que la précision de T_{fin} est meilleure que celles de T_{mdl} et T_{man} considérées séparément, ce qui signifie que le mécanisme de génération de trajectoires et la fonction de mixage des deux trajectoires sont efficaces.

On remarque toutefois, sur la figure 4.12.d par exemple, que le changement de voie ne se termine pas exactement sur la ligne centrale de la voie adjacente. Ainsi, le fait d'imposer que les manœuvres se terminent sur les centres des voies peut créer des erreurs de prédiction à fin de la manœuvre qui se traduisent par des dépassements (overshoots). Pour éviter cet effet, une solution possible serait d'effectuer en plus un échantillonnage latéral pour fixer le point final de la manœuvre afin prendre en compte les points situés hors de la ligne centrale de la voie. Une autre solution est de faire varier la fonction de pondération de T_{mdl} et T_{man} de façon à ce que, lorsque le véhicule est déjà très proche du centre de la voie cible, T_{man} ait moins d'influence sur le résultat final. Dans les deux cas, et surtout pour le premier, l'opération supplémentaire générerait plus de calculs.

Dans la suite de ces résultats, nous évaluons le risque de collision avec la trajectoire T_{fin} telle que présentée car ses performances nous semblent tout à fait acceptables.

4.8.2 Calcul de risque de collision

Les résultats de cette section sont réalisés dans les conditions suivantes qui nous semblent très réalistes vis-à-vis d'une application en temps réel :

- la trajectoire future est échantillonnée toutes les 100ms
- A chaque instant d'échantillonnage, 100 tirages aléatoires (seulement) sont réalisés pour faire le calcul de risque.

Résultats de simulation sur un premier scénario

Dans un premier scénario simulé, l'égo-véhicule, roulant initialement derrière un autre véhicule noté V_1 , essaye dépasser ce dernier. Il change alors de voie et pendant qu'il arrive presque à hauteur de V_1 , ce dernier change également de voie pour dépasser un troisième véhicule (noté V_2) se trouvant devant lui. Il cause alors une collision avec l'égo-véhicule. L'objectif est de vérifier et de valider l'évolution de la probabilité de collision de l'égo-véhicule avec V_1 durant la simulation, jusqu'au moment de la collision. Le scénario dure 12s au total et la collision a lieu à 7,4s. L'égo-véhicule se déplace en moyenne à 80km/h, V_1 à 50km/h et V_2 à 40km/h. La période d'échantillonnage simulée est de 10hz.

Pour cette expérimentation, nous avons directement utilisé les données simulées du générateur de scénarios pour faire les prédictions des trajectoires des objets. Ensuite, à chaque période de simulation, les trajectoires des objets sont prédites sur 4s. Les paramètres de réglages sont les mêmes que ceux de l'expérimentation décrite dans la section 4.8.1. A partir des trajectoires prédites à chaque pas de simulation, le risque de collision de l'égo-véhicule avec chacun des autres véhicules est calculé pour chaque instant futur échantillonné sur l'horizon de prédiction. Les tracés des probabilités de collision obtenues à différents moments de la simulation sont montrés sur les figures 4.14, 4.15 et 4.16. Dans chaque sous-figure, le graphe du haut montre une vue aérienne du scénario et les deux graphes suivants montrent le tracé de la probabilité de collision avec chaque véhicule, sur l'horizon de prédiction.

On remarque que le pic de la probabilité de collision avec le véhicule V_1 est toujours situé au moment réel de la collision et que sa valeur croît au fur et à mesure qu'on se rapproche de la collision. C'est le comportement souhaité car il permet ainsi d'alerter le conducteur proportionnellement au temps qui le sépare de la collision. En s'intéressant de plus près aux valeurs atteintes, on remarque que le risque de collision atteint déjà les 60% lorsqu'on est à environ 1.5s de l'accident ce qui laisse au conducteur, relativement assez de temps pour réagir. Lorsqu'on est à moins d'une seconde, il atteint les 80% témoignant de l'urgence d'entamer une manœuvre d'évitement de collision. Il atteint les 100% autour de 0.5s car le temps disponible ne permet généralement plus d'éviter la collision. En ce qui concerne le véhicule V_2 , le risque de collision existe malgré le fait que les deux véhicules ne sont pas sur la même voie. Ceci est dû à l'imprécision de la localisation des véhicules. De plus, dans la simulation, les voies sont assez étroites par rapport à la largeur des objets. Le pic de risque atteint est inférieur à 40% et est, en moyenne, inférieur à 20% ce qui signifie que la risque de collision avec V_2 reste faible.

Résultats de simulation sur un second scénario

Dans le second scénario simulé, l'égo-véhicule suit un véhicule V_1 puis fait un changement de voie pour effectuer un dépassement. Pendant qu'il est sur la voie de gauche,

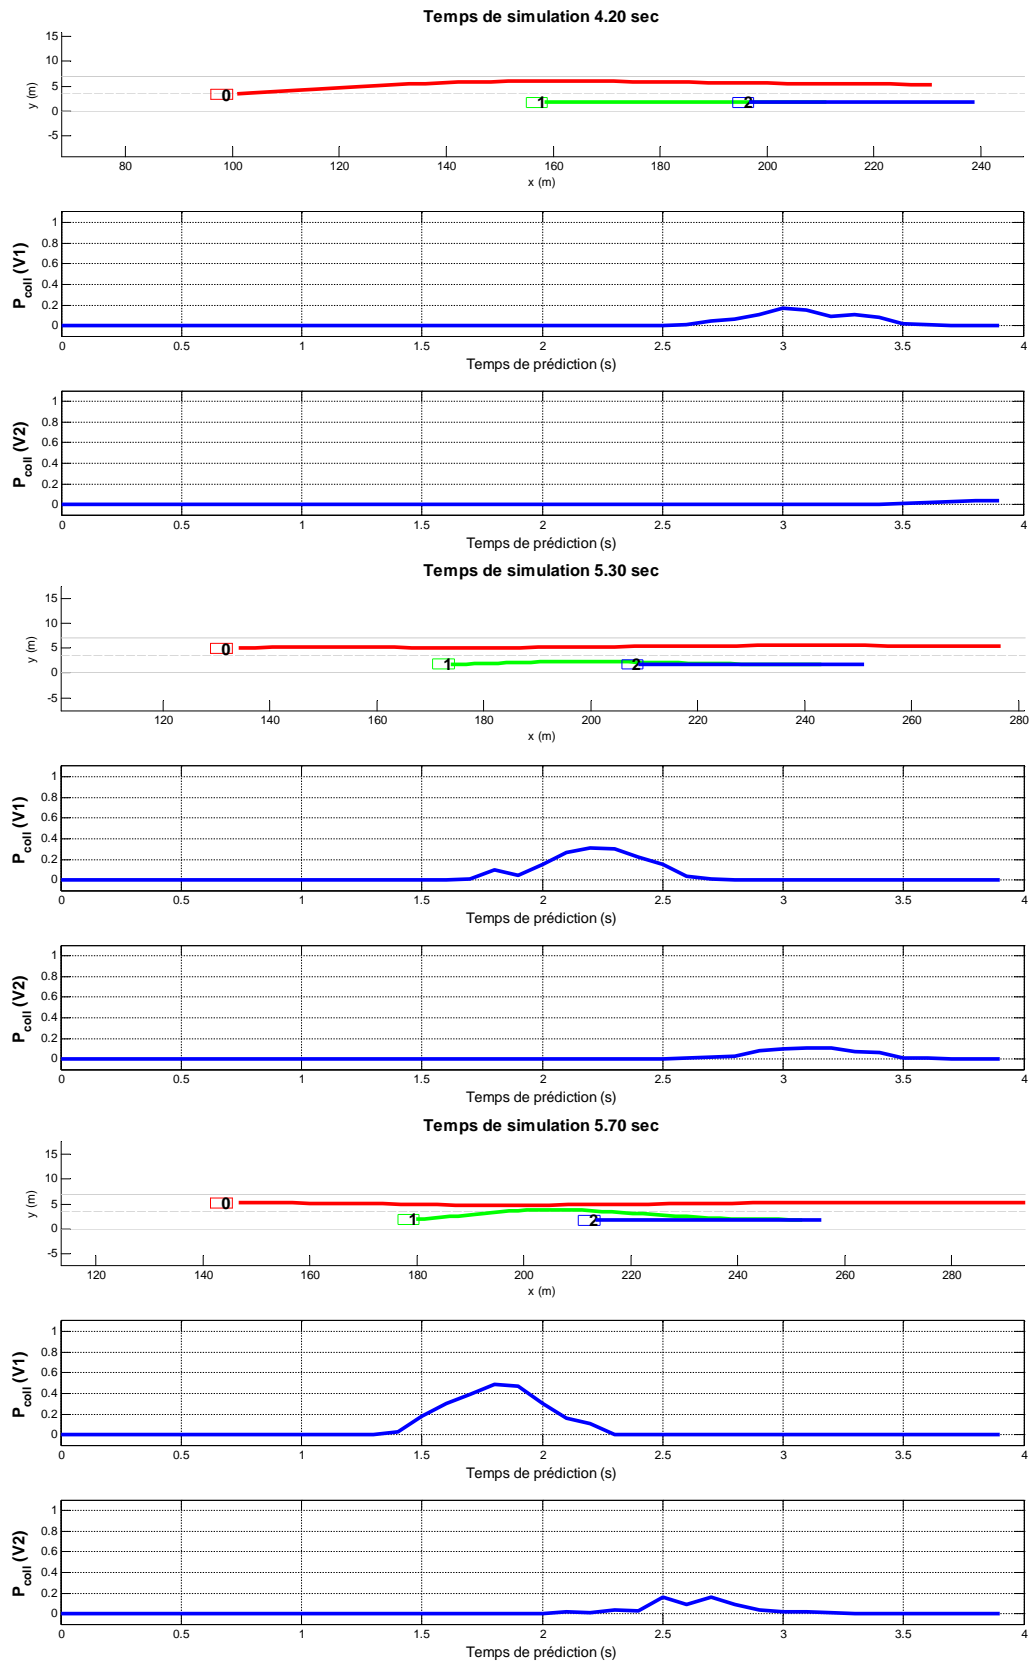


Figure 4.14: Évolution de la probabilité de collision avec chaque véhicule : Scénario 1, jusqu'à $t=5.7s$

4.8 Résultats d'expérimentation et analyses




Figure 4.15: Évolution de la probabilité de collision avec chaque véhicule : Scénario 1, jusqu'à $t=6.4s$




Figure 4.16: Évolution de la probabilité de collision avec chaque véhicule : Scénario 1, jusqu'à t=7.4s

un véhicule V_2 arrive en sens inverse sur la même voie. L'égo-véhicule se rabat ensuite sur la voie de droite après le dépassement et la collision est évitée de justesse. L'égo-véhicule roule à 50km/h et les deux autres véhicules à 40km/h. L'objectif ici est de vérifier le risque de collision avec V_2 . Les figures 4.17, 4.18 et 4.19 montrent l'évolution du risque de collision au cours la simulation.

Dans ce scénario, il n'y a pas eu de collision et il faut remarquer qu'effectivement le risque de collision avec V_2 n'atteint jamais 100%. Il reste plutôt faible même lorsque les deux véhicules se retrouvent en sens inverses sur la même voie car, au début, ils sont assez éloignés (plus de 100m sur la figure 4.17.c) et plus tard, le changement est détecté et confirme que les trajectoires ne se rencontrent pas. Lorsque les deux véhicules se rapprochent, malgré que leur trajectoires futures ne se croisent pas, le risque de collision croît en raison de l'imprécision de la localisation. Les pics atteints sur les figures 4.18.c et 4.19.a montrent qu'on est quand même passé près d'une collision. Notons que les prédictions de trajectoire ont une importance capitale sur le résultat. Pour le véhicule V_1 , l'analyse est semblable à celle du véhicule V_2 dans le scénario 1.

Nous estimons que les valeurs obtenues reflètent assez bien le risque de collision par rapport aux scénarios. Cependant, dans la pratique, ce sont finalement les seuils définis arbitrairement pour effectuer une action donnée ou une alerte qui rendent compte de la sensibilité du système d'alerte au risque de collision. Il faut donc les définir convenablement et les adapter au contexte de conduite. Les résultats obtenus en général témoignent que la méthode de prédiction de trajectoire utilisée et la méthode de propagation de l'incertitude sont assez bonnes et les calculs de risque réalisés reflètent bien la réalité de la situation.

4.9 Conclusion

L'objet de ce chapitre était d'analyser la scène perçue afin de rendre compte du risque de collision encouru par l'égo-véhicule. Pour ce faire nous avons montré qu'il fallait d'abord prédire l'évolution de la scène en prédisant la trajectoire des objets mobiles. La méthode de prédiction proposée est applicable aussi bien à l'égo-véhicule qu'aux autres véhicules et consiste à faire deux sous-prédictions qui sont combinées pour obtenir la trajectoire finale. Il s'agit d'une prédiction supposant un mouvement à accélération et vitesse de lacet constantes et d'une prédiction basée sur un module de reconnaissance de manœuvre. Le modèle de mouvement utilisé garantit une bonne précision pour les prédictions à court terme mais devient très imprécis à moyen et long terme. Le module de reconnaissance de manœuvre sert à prédire la voie sur laquelle le véhicule considéré ira prochainement mais il existe un retard de détection au début d'une nouvelle manœuvre. Ensuite, nous utilisons un modèle polynomial pour mieux approximer le mouvement du véhicule. La combinaison des deux trajectoires prédites permet de profiter des avantages de chacune d'elles.




Figure 4.17: Évolution de la probabilité de collision avec chaque véhicule : Scénario 2, jusqu'à t=8.2s




Figure 4.18: Évolution de la probabilité de collision avec chaque véhicule : Scénario 2, jusqu'à t=10.4s




Figure 4.19: Évolution de la probabilité de collision avec chaque véhicule : Scénario 2, jusqu'à $t=11.3s$

Ensuite, pour estimer le risque de collision, l'incertitude sur l'estimation de la pose courante de chaque objet est propagée le long de sa trajectoire prédite grâce à une formulation particulière qui permet de faire ce calcul malgré le fait que la trajectoire prédite ne soit connue que de façon discrète. Ainsi, en considérant des instants échantillonnés du futur, les poses associées correspondent chacune à un vecteur aléatoire dont connaît la moyenne et la matrice de covariance. Ceci donne la possibilité d'évaluer la probabilité que deux objets quelconques soient en collision à un instant donné. En raison de l'impossibilité de déterminer une expression analytique de cette probabilité, elle est estimée numériquement par une simulation de Monte-Carlo qui prend en compte une boîte englobante des véhicules pour faire les calculs. On obtient finalement une valeur de risque de collision pour chaque horizon de prédiction.

Ces approches ont été testées sur des données simulées et les résultats obtenus montrent que l'interprétation de la scène perçue reflète bien la configuration et le contexte de la scène réelle. Au delà de l'analyse des résultats, nous avons proposés quelques pistes d'amélioration qui seront appliquées dans nos travaux futurs.

Chapitre 5

Conclusions et perspectives

5.1 Conclusions

Ce travail de recherche a été consacré à l'étude de systèmes d'aide à l'évitement de collision, l'objectif étant d'obtenir un système embarqué capable d'évaluer continuellement le risque de collision de l'égo-véhicule avec les obstacles potentiels et de calculer une trajectoire d'évitement lorsque ce risque devient assez important.

L'architecture que nous avons étudiée se compose de 3 parties principales : un Système de Perception (SP), un Module d'Analyse de Scène (MAS) et un Module de Décision (MD). Les travaux présentés dans ce mémoire ont concerné essentiellement le SP et le MAS.

Le SP comprend des "capteurs intelligents" (*smart sensors*) de technologies différentes qui perçoivent l'environnement autour du véhicule et qui communiquent à une unité centrale, au moyen d'un réseau embarqué, des résultats issus de pistages locaux. Nous avons proposé un modèle d'abstraction de capteur qui offre une grande modularité. Le système de fusion de pistes est synchrone et cadencé au rythme du capteur le plus rapide. Il exploite des estampilles de temps ramenées dans un référentiel commun. La méthode de fusion intègre un algorithme d'association itératif robustifié par la prise en compte de l'historique des pistes. La fusion se fait époque par époque (sans mécanisme prédictif/estimateur) afin de limiter l'inconsistance générée par l'inter-corrélation de modèles d'évolution. Le calcul de la confiance des pistes du système exploite la persistance et la redondance dans les zones de recouvrement des capteurs, à l'aide d'une machine à états. Les différentes étapes clés du SP ont été évaluées en simulation et sur des données réelles.

Le repère de travail constitue un choix important que nous avons discuté. Le choix s'est porté sur un repère halo-centré au regard des contraintes imposées par le Module d'Analyse de Scène. Ainsi, le SP fournit à chaque itération, dans un repère fixe, la liste des pistes confirmées correspondant aux objets représentant des obstacles potentiels.

Le MAS a pour rôle d'évaluer le risque de collision de l'égo-véhicule avec les objets détectés dans l'environnement du véhicule. Ce calcul repose sur les prédictions de

trajectoire des objets (y compris l'égo-véhicule) sur un horizon de quelques secondes. Nous avons proposé une méthode qui combine une trajectoire prédite en admettant un mouvement à accélération tangentielle et vitesse de lacet constantes et une trajectoire prédite à partir de la reconnaissance de la manœuvre de l'objet considéré. Cette approche exploite les avantages de chaque type de prédiction, notamment la précision à court terme de la première et la meilleure précision à long terme de la deuxième. L'incertitude des poses prédites est estimée de façon récursive à partir de l'incertitude initiale et permet d'estimer la probabilité de collision, pour divers horizons de prédiction, par une simulation de Monte-Carlo. La prédiction de trajectoire et le calcul de risque ont été évalués sur des données simulées.

Les principales contributions de ces travaux sont à nos yeux les suivantes :

- un moteur de fusion de pistes issues de capteurs de modalités différentes. Notre système est assez modulaire et évolutif car il permet de faire varier le nombre et le type des capteurs et pourrait facilement intégrer de nouvelles technologies de perception (Car-To-Car Communication par exemple). Étant donné que le système manipule des données élaborées à partir de “boîtes noires” les approches classiques de fusion étaient à reconsidérer avec attention. Nous avons proposé des méthodes d'association, de fusion et de gestion de la confiance qui permettent de s'affranchir, dans une certaine mesure, de la connaissance fine des données brutes d'entrée,
- une méthode de reconnaissance de manœuvre qui n'utilise pas une base de données d'apprentissage. Notre approche repose sur la modélisation de la trajectoire locale du véhicule et des lignes centrales des voies par des arcs de cercle. Ensuite, leur similarité est évaluée par des méthodes statistiques qui prennent en compte les données acquises sur un horizon fini,
- une méthode de prédiction de trajectoire qui combine deux types de prédiction complémentaires afin rendre la prédiction finale plus fiable, notamment sur du long terme et lorsque la route présente une courbure non nulle,
- une méthode de propagation de l'incertitude de pose (position et orientation) le long de la trajectoire prédite pour le calcul du risque de collision. Comme la trajectoire n'est connue que sous une forme discrète, le principe que nous avons proposé consiste à approximer localement le mouvement comme étant linéaire à vitesse constante. L'approximation et par conséquent le résultat obtenu sont d'autant plus corrects que l'échantillonnage est fin.

5.2 Perspectives

Les travaux que nous avons menés sur le troisième module de l'application, le Module de Décision, n'ont malheureusement pas encore abouti à des résultats validés. Nous présentons ici quelques principes et les approches prometteuses parmi celles que nous avons explorées.

5.2.1 Détermination de la manœuvre d'évitement de collision

Dans le chapitre précédant, nous avons vu comment évaluer continuellement le risque de collision de l'égo-véhicule avec les autres objets de la scène. Dès que la probabilité de collision avec un objet atteint une valeur importante pour un temps-avant-collision relativement faible, alors le système doit calculer une trajectoire permettant d'éviter la collision. Les deux seuils de probabilité et de temps-avant-collision sont définis arbitrairement en fonction de la sensibilité souhaitée pour le système. La trajectoire planifiée doit tenir compte de l'évolution de la scène afin que l'égo-véhicule n'entre pas en collision avec un autre objet durant la manœuvre d'évitement de collision.

Pour planifier une trajectoire, il faut d'abord définir un objectif à atteindre. Dans notre cas, il s'agit d'un état jugé sécurisé au regard de l'éventualité d'une collision. Ensuite, il faut chercher le moins "couteux", au regard de la sécurité, pour y parvenir. Nous allons d'abord brièvement étudier ce critère de sécurité avant de venir sur le calcul de la trajectoire à planifier puisqu'il intervient à tout moment.

Critère de sécurité

Plusieurs concepts existent dans la littérature pour évaluer la sécurité de l'état d'un véhicule dans un environnement dynamique. Par exemple, les *états de collision inévitable* (ICS¹) [Martinez-Gomez and Fraichard, 2008] [Fraichard and Asama, 2003]. Un ICS est un état dans lequel l'égo-véhicule, quelle que soit sa future manœuvre, ne peut éviter une collision avec au moins un objet. Pour illustrer simplement ce concept, considérons un cas où l'égo-véhicule se déplace sur une voie où il existe un obstacle fixe. Dans ces conditions, une collision aura sans doute lieu si le véhicule ne change pas de comportement. Maintenant, nous allons admettre que selon sa vitesse actuelle qui est supposée constante, l'égo-véhicule ne peut varier son angle au volant, que dans une certaine limite, pour garder sa stabilité. Cette marge de manœuvre est représentée par le secteur de disque rouge sur la figure 5.1. Le triangle en fond gris représente un ensemble d'états où la collision ne pourra plus être évitée. Cette zone est à éviter en tout temps tant que l'égo-véhicule conserve sa vitesse actuelle. Son envergure dépend de l'état actuel de l'égo-véhicule, de ces limites physiques (marge de manœuvre) et de la position de l'obstacle.

Cette représentation extrêmement simplifiée explique bien le concept mais ne rend pas compte de toute sa complexité. En effet, dans un cas plus réaliste, le modèle de mouvement de l'égo-véhicule n'est pas aussi simple, il existe plusieurs obstacles, qui sont potentiellement mobiles eux aussi et on maîtrise mal la trajectoire future. La

1. Inevitable Collision State




Figure 5.1: Illustration de l'ICS. Si l'égo-véhicule se retrouve dans la zone triangulaire en fond gris, la collision sera inévitable

définition de tous les ICS en fonction du temps devient alors un problème complexe qui ne peut généralement pas être résolu analytiquement. Pour le résoudre numériquement, il faut alors effectuer un échantillonnage de l'espace d'état de l'égo-véhicule et évaluer chaque cas, ce qui demande une grande puissance de calcul si on fait un échantillonnage fin.

Certaines approches comme les *Velocity Obstacles* (VO) [Fiorini and Shiller, 1998, Large et al., 2004] reposent sur un principe semblable mais avec des hypothèses simplificatrices sur le mouvement des objets afin de réduire l'espace de recherche. Notamment, on admet que les objets ont un mouvement linéaire à vitesse constante.

Les approches citées précédemment donnent, au prix d'une complexité calculatoire non négligeable, des résultats assez "fins" pour la planification de trajectoires en robotique en général. Avec des considérations plus "grossières" mais qui sont parfaitement acceptables du point de vue de l'aide à la conduite en automobile, on peut s'affranchir d'une bonne partie de ces calculs. On peut considérer qu'il existe un nombre limité de façons d'éviter une collision. Généralement, il s'agit de freiner tout en restant dans sa voie de circulation ou de se déporter latéralement pour contourner l'obstacle. On peut sans doute imaginer quelques scénarios supplémentaires mais ces deux là sont les plus classiques. Pour le freinage par exemple, il n'y a quasiment pas de contrainte à prendre en compte vis-à-vis des autres objets de l'environnement puisque le véhicule reste dans sa voie de circulation et doit justement éviter le premier obstacle sur cette voie. Pour la deuxième manœuvre, l'égo-véhicule peut potentiellement avoir besoin de sortir de sa voie initiale et donc risquer de rentrer en collision avec un obstacle qui se trouve sur le côté choisi. Dans ce cas, les contraintes sont plus fortes mais des règles de décision simples sur lesquelles nous allons revenir peuvent être utilisées pour garantir la sécurité de la manœuvre ou l'interdire.

Calcul de trajectoire d'évitement de collision

Certaines méthodes de planification de trajectoire dite réactives sont parfaitement adaptées aux principes des ICS et des VO. Elles consistent à faire des planifications de façon itérative sur de courtes périodes de temps. Les prédictions de trajec-




Figure 5.2: Scénarios de collision considérés. L’objet à éviter est dessiné en rouge et l’égo-véhicule en noir. (a) l’objet se trouve initialement dans la même voie que l’égo-véhicule. (b) l’objet s’insère dans la voie de l’égo-véhicule

toire sur une période d’échantillonnage sont très précises, même avec des modèles simples, et l’espace d’état de recherche est moins important. A chaque itération, la marge de manœuvres possibles de l’égo-véhicule est échantillonnée et celle qui minimise une fonction de cout au regard de la sécurité et de l’objectif à atteindre est choisie. Des techniques d’échantillonnage et de sélection sont disponibles dans [Fraichard and Howard, , Hundelshausen et al., 2008]. La trajectoire finale est donc construite pas à pas et offre une excellente réactivité dans une scène dynamique. Par contre, en raison du faible horizon temporel considéré, le résultat peut ne pas être adapté à un environnement routier.

D’autres méthodes de planification que nous qualifions de “complètes” supposent que les prédictions de trajectoire sur quelques secondes sont correctes et que le niveau de réactivité nécessaire lors de la manœuvre d’évitement de collision, n’est pas si élevé tant que l’on tient compte des contraintes des trajectoires prédites. Ainsi, elles cherchent à calculer la trajectoire complète en une fois, en utilisant des modèles d’équations paramétrés en fonction du temps [Köhler et al., 2013, Keller et al., 2011, Hillenbrand et al., 2006].

Nous avons privilégié ce type d’approche qui nous paraît plus adapté à un système d’aide à la conduite.

Approche envisagée

L’approche qui nous semble la plus intéressante consiste à considérer le freinage et le déport latéral comme les 2 types de manœuvres d’évitement de collision possibles. Nous considérons donc les deux scénarios de collision de la figure 5.2.

A chaque type de manœuvre est associé un modèle d’équations puis la trajectoire est obtenue en définissant le point de départ de la manœuvre et le point d’arrivée. Pour déterminer le point de départ, quel que soit le type de la manœuvre, nous partons de la prémisse que le système ne doit (éventuellement) intervenir sur les commandes du véhicule que le plus tard possible, afin de laisser la main au conducteur le plus longtemps possible. Il faut donc calculer la durée maximale de “conduite normale” disponible avant pouvoir éviter la collision juste à temps, par le type de

manœuvre considéré. Le point est alors déduit de la trajectoire prédite de l'égo-véhicule. Le point d'arrivée est défini en fonction de la position de l'impact prévu. Les durées maximales de "conduite normale", que nous notons respectivement TTB (Time-To-Brake) pour le freinage, TTS (Time-To-Steer) pour le déport latéral, sont des métriques de temps qui serviront à faire le choix d'une des deux manœuvres d'évitement de collision.

Nous rappelons que l'état de tout objet considéré est représenté par le vecteur

$$X = [x, y, \theta, v, a, \omega]$$

composé des paramètres abscisse, ordonnée, angle de lacet, vitesse linéaire, accélération tangentielle et vitesse de lacet.

Nous rappelons également que pour toutes les trajectoires prédites, l'accélération tangentielle est supposée constante. Adoptons les notations suivantes :

- a_{ego} , accélération tangentielle de l'égo-véhicule à l'instant courant
- $v_{ego,0}$, vitesse linéaire de l'égo-véhicule à l'instant courant
- $v_{obj,imp}$, vitesse linéaire prévue de l'objet à éviter, au moment de l'impact

Évitement de collision par freinage dans la même voie

La manœuvre d'évitement de collision consiste à freiner jusqu'à ce que la vitesse de l'égo-véhicule atteigne celle que l'objet à éviter aura au moment de l'impact, avant que la distance entre l'égo-véhicule et la position de l'impact prévu n'atteigne une distance de sécurité d_{secur} . Puisque toute l'opération se situe dans une même voie, le problème peut être ramené à une seule dimension. Nous admettons ainsi que le contrôle latéral de l'égo-véhicule qui consiste simplement à rester dans la voie n'est pas un problème. Il s'agit alors de fournir l'équation du temps correspondant à la distance parcourue par l'égo-véhicule. Pour obtenir le TTB, on admet que le freinage se fait avec une décélération constante et égale à la décélération maximale possible. Ce paramètre sera noté a_{frein} et est considéré comme connu. En pratique, il est de l'ordre de $1G \approx 10m/s^2$ c'est-à-dire environ $10m/s^2$, en valeur absolue. Le freinage commence donc au bout de TTB secondes et l'équation de la distance parcourue au cours du freinage est de la forme

$$d_{frein}(t) = \frac{1}{2}a_{frein} \cdot t^2 + v_{ego,tb} \cdot t$$

où $v_{ego,tb}$ est la vitesse de l'égo-véhicule au commencement de la manœuvre. Puisque l'accélération a_{ego} de l'égo-véhicule est supposée constante, on a

$$v_{ego,tb} = a_{ego} \cdot TTB + v_{ego,0}$$

Il faut maintenant déterminer TTB . Le scénario se compose donc d'une phase de "conduite normale" suivie d'une phase de freinage. En notant d_{imp} la distance séparant l'égo-véhicule de la position de l'impact le long de la voie, et t_{frein} la durée de la phase de freinage, l'équation du mouvement donne :

$$\left(\frac{1}{2}a_{ego} \cdot TTB^2 + v_{ego,0} \cdot TTB\right) + \left(\frac{1}{2}a_{frein} \cdot t_{frein}^2 + (v_{ego,0} + a_{ego} \cdot TTB) t_{frein}\right) + d_{secur} = d_{imp} \quad (5.1)$$

t_{frein} est le temps qu'il faut à l'égo-véhicule pour passer de sa vitesse après TTB secondes ($v_{ego,ttb}$), à la vitesse de l'objet au moment de l'impact ($v_{obj,imp}$), avec une accélération constante, a_{frein} . Ceci se traduit par l'équation

$$t_{frein} = \frac{v_{obj,imp} - (v_{ego,0} + a_{ego} \cdot TTB)}{a_{frein}}$$

avec $a_{frein} \neq 0$.

En remplaçant t_{frein} par son expression dans l'équation 5.1 et en simplifiant le résultat, on obtient une fonction de TTB sous la forme d'un polynôme du second degré :

$$c_2 \cdot TTB^2 + c_1 \cdot TTB + c_0 = 0$$

avec

$$\begin{aligned} c_2 &= \frac{1}{2} (a_{ego} a_{frein} - a_{ego}^2) \\ c_1 &= a_{frein} v_{ego,0} - a_{ego} v_{obj,imp} + (v_{obj,imp} - v_{ego}) a_{ego} a_{frein} \\ c_0 &= \frac{1}{2} (v_{ego,0}^2 - v_{obj,imp}^2) + a_{frein} (d_{secur} - d_{imp}) \end{aligned}$$

La résolution de ce type d'équation est triviale et TTB correspond à la plus petite racine réelle positive. S'il n'y a pas de solution admissible alors la collision ne pourra pas être évitée par freinage mais le freinage peut-être déclenché pour réduire l'impact du choc.

Évitement de collision par déport latéral

Cette fois-ci, la manœuvre consiste à éviter la collision en se déportant latéralement vers la gauche ou vers la droite. Cette manœuvre peut potentiellement faire sortir

l'égo-véhicule de sa voie initiale et, contrairement au cas précédant, elle peut éventuellement causer une collision avec un véhicule se trouvant sur la voie latérale, du côté choisi. Pour simplifier les explications, nous allons considérer que la manœuvre se déroule sur une section de route rectiligne. Pour une section courbe, le calcul de la trajectoire se fait d'abord dans la base de Frenet le long de la ligne centrale de la voie initiale de l'égo-véhicule puis on fait une conversion vers le repère de travail initial (voir 4.5.1).

Notons (x_{imp}, y_{imp}) la position de l'impact prévu. L'objectif est de mener l'égo-véhicule de sa position, au début de la manœuvre, vers le point $(x_{imp}, y_{imp} + d_{secur})$. d_{secur} est un écart relatif qui garantit qu'il n'y a pas de contact avec l'objet à la fin de la manœuvre. Son signe définit la direction du déport (gauche ou droite). Sa valeur dépend de la dimension des objets et inclut une marge de sécurité. S'il existe deux voies latérales, les deux possibilités de point d'arrivée sont considérées. La méthode proposée consiste à modéliser le chemin entre le point de départ de la manœuvre et le point d'arrivée par un polynôme de degré 3 de la forme.

$$y_{path}(x) = c_3x^3 + c_2x^2 + c_1x + c_0$$

Puisque le point de départ, n'est pas encore connu, on considère les points de la trajectoire prédite de l'égo-véhicule comme points de départ potentiels. Chaque point, noté (x_k, y_k) , de la trajectoire prédite correspond à un instant t_k de l'intervalle de prédiction échantillonné $T^K = \{t_0, t_1, \dots, t_k, \dots, t_K\}$. Connaissant la tangente en chacun de ces points, et en imposant qu'à l'arrivée l'axe du véhicule soit parallèle à celui de la route, nous pouvons calculer les coefficients des polynômes et ainsi obtenir un ensemble $PATH^K$ de chemins possibles (voir figure 5.3) :

$$PATH^K = \{path_k | k = 0..K\}$$

Ensuite, il faut sélectionner le meilleur chemin sachant que l'objectif est que le véhicule suive ce chemin en gardant sa vitesse constante. Nous admettons que pendant la manœuvre, on arrête d'accélérer, sans pour autant freiner et que l'inertie du véhicule fait que sa vitesse reste quasiment constante.

La première contrainte à respecter est que le véhicule ne peut supporter qu'une accélération normale maximale $a_{n,max}$ supposée connue. Sa valeur varie suivant les véhicules mais en pratique le seuil admis est d'environ $0,6G$. Pour un chemin $path_k$, l'accélération normale en un point d'abscisse x est donnée par le produit de la courbure $\gamma_k(x)$ du chemin en ce point par le carré de la vitesse $v_{ego,k}$ de l'égo-véhicule au début de la manœuvre :

$$a_{n,k}(x) = v_{ego,k}^2 \gamma_k(x)$$




Figure 5.3: Génération de chemins pour déterminer la manœuvre d'évitement de collision par déport latéral

avec

$$\gamma_k(x) = \frac{y''_{path,k}(x)}{(1 + y'^2_{path,k})^{3/2}} = \frac{6c_3x + 2c_2}{(1 + (3c_3x^2 + 2c_2x + c_1)^2)^{3/2}}$$

L'accélération normale maximale subie par le véhicule pour un chemin considéré est obtenue en déterminant le maximum, noté $\gamma_{max,k}$ de $\gamma_k(x)$ sur l'intervalle $[x_k, x_{imp}]$. Tous les chemins pour lesquels $v_{ego,k}^2 \cdot \gamma_{max,k} > a_{n,max}$ sont donc exclus.

Ensuite, il faut exclure les cas où le véhicule risque d'entrer en collision avec un autre obstacle. Les obstacles considérés sont ceux dont la trajectoire prédite arrive dans l'une des voies adjacentes et à hauteur de $[x_k, x_{imp}]$, dans l'intervalle de temps $[0, TTC]$. Il faut alors réévaluer le risque de collision avec chacun d'eux, en considérant, cette fois-ci, respectivement les trajectoires d'égo-véhicule correspondant aux chemins générés restants. Puisque ce traitement peut être assez coûteux en temps de calcul et que les contraintes de sécurité sont très élevées afin d'éviter une collision qui pourrait être plus grave que celle que l'on cherche à éviter, nous proposons une règle de sélection qui exclut tout déport latéral du côté où il existe au moins un obstacle respectant la condition citée.

Si à cette étape il reste plusieurs possibilités, le chemin $path_p$ choisi est celui qui commence le plus tard c'est-à-dire celui ayant x_k maximal et le TTS est égal à l'intervalle de temps t_p correspondant.

Choix de la manœuvre à exécuter

Selon la configuration de la scène, il peut arriver que les deux manœuvres soient possibles pour éviter une collision. Il faut alors définir une stratégie de choix. Dans

[Keller et al., 2011], le système privilégie toujours l'évitement par freinage car cette manœuvre est plus sécurisée que la seconde. Le problème est que, à vitesse élevée, le freinage doit commencer assez tôt alors qu'il est possible d'éviter la collision plus tard en se déportant. En respectant le principe demandant de laisser la main au conducteur le plus longtemps possible, il faudrait alors choisir la manœuvre qui demande à être commencée le plus tard (en comparant TTB et TTB). Cependant, la règle "prudente" demanderait plutôt à choisir celle qui demande à être commencée le plus tôt afin avoir plus de temps de manœuvre. Il n'y a pas une réponse optimale à cette question. Une autre possibilité serait de laisser l'utilisateur configurer le comportement qu'il souhaite. Dans tous les cas, le Forum mondial pour l'harmonisation des réglementations sur les véhicules (World Forum for Harmonization of Vehicle Regulations), aussi appelé WP.29 et qui est un groupe de travail de l'UNECE¹ exige que le conducteur soit d'abord maître des commandes du véhicule. Donc, quel que soit le choix effectué, les actions, s'il réagit, doivent "écraser" celle du système.

5.2.2 Perspectives à plus long terme

Pour compléter la conception du système d'aide à l'évitement de collision étudié, il faut développer le module de commande des actionneurs du véhicule. Son rôle est de déterminer les lois de commande permettant de respecter au mieux la trajectoire calculée. En plus, il convient de développer une Interface Homme-Machine (IHM) qui, d'une part, génère les alertes correspondant aux divers seuils de risque de collision définis et, d'autre part, permet à l'utilisateur de régler la sensibilité ou le comportement du système. Ces travaux, qui n'ont pas fait partie des objectifs de cette thèse, ne sont cependant pas les moindres et font l'objet de nombreuses recherches.

1. United Nations Economic Commission for Europe

Chapitre 6

Annexes

6.1 Situations accidentelles

Les situations relatives aux pertes de contrôle et aux problèmes de guidage

1. Perte de contrôle et problème de guidage en ligne droite, impliquant un seul usager hors intersection.
2. Perte de contrôle et problème de guidage en ligne droite, impliquant deux usagers hors intersection.
3. Perte de contrôle et problème de guidage en virage, impliquant un seul usager hors intersection.
4. Perte de contrôle et problème de guidage en virage, impliquant deux usagers hors intersection.
5. Perte de contrôle et problème de guidage impliquant un seul usager en intersection.
6. Collision contre véhicule en stationnement.
7. Collision avec un animal.

Les situations relatives aux accidents de piétons

1. Conducteur confronté à un piéton longeant la route.
2. Conducteur confronté à un piéton traversant la route.
3. Conducteur confronté à un piéton initialement masqué.
4. Conducteur confronté à un piéton lors d'une manœuvre de marche arrière.
5. Conducteur confronté à un piéton jouant ou courant.

Les situations relatives aux conducteurs accidentés hors intersection, sans piéton, ni problème de perte de contrôle ou de guidage

1. Conducteur circulant en virage sans manœuvre spécifique, confronté à un autre usager qui vient le heurter.
2. Conducteur circulant en ligne droite sans manœuvre spécifique, confronté à un autre usager qui vient le heurter.
3. Conducteur heurté dans une collision fronto-arrière.
4. Conducteur heurtant dans une collision fronto-arrière.
5. Conducteur changeant de file de circulation.
6. Conducteur contournant un obstacle.
7. Conducteur effectuant un dépassement.
8. Conducteur effectuant une manœuvre de stationnement.
9. Conducteur tournant à gauche ou à droite, hors intersection.
10. Ouverture de portière.
11. Conducteur effectuant un demi-tour sur chaussée.
12. Conducteur traversant la chaussée, hors intersection.
13. Conducteur dans son véhicule en stationnement.

Les situations relatives aux conducteurs accidentés en intersection.

1. Conducteur présumé responsable en giratoire sans manœuvre de tourne à droite, à gauche ou insertion dans l'accident.
2. Conducteur présumé non-responsable en giratoire sans manœuvre de tourne à droite, à gauche ou insertion dans l'accident.
3. Conducteur confronté à un usager tournant à droite, à gauche ou s'insérant dans un giratoire.
4. Conducteur en manœuvre d'insertion dans un giratoire.
5. Conducteur en manœuvre de tourne à droite dans un giratoire.
6. Conducteur en manœuvre de tourne à gauche dans un giratoire.
7. Conducteur présumé responsable d'un accident entre deux véhicules sur chaussée sécante, sans manœuvre de tourne à droite ou à gauche.
8. Conducteur présumé non-responsable d'un accident entre deux véhicules dans une intersection à chaussée sécante, sans manœuvre de tourne à droite ou à gauche.
9. Conducteur adverse des situations 10 et 11.

10. Conducteur en manœuvre de tourne à gauche dans une intersection à chaussée sécante.
11. Conducteur en manœuvre de tourne à droite dans une intersection à chaussée sécante.
12. Conducteur présumé responsable d'un accident de croisement de véhicules en intersection, sans manœuvre de tourne à droite ou à gauche.
13. Conducteur présumé non-responsable d'un accident de croisement de véhicules en intersection sans manœuvre ou avec manœuvre de tourne à droite ou à gauche du véhicule adverse.
14. Conducteur présumé responsable d'un accident avec manœuvre de tourne à gauche devant véhicule venant en sens inverse.
15. Conducteur présumé responsable d'un accident avec manœuvre de tourne à droite avec véhicule venant en sens inverse.
16. Conducteur présumé responsable d'un accident entre véhicules circulant dans le même sens en intersection, sans manœuvre de tourne à droite ou à gauche.
17. Conducteur présumé non-responsable d'un accident entre véhicules circulant dans le même sens en intersection, sans manœuvre de tourne à droite ou à gauche. 4
18. Conducteur adverse de la situation 19.
19. Conducteur en manœuvre de tourne à gauche en intersection dans un accident entre véhicules circulant dans le même sens.
20. Conducteur adverse de la situation 21.
21. Conducteur en manœuvre de tourne à droite en intersection dans un accident entre véhicules circulant dans le même sens.
22. Conducteur effectuant un demi-tour en intersection.
23. Conducteur adverse de la situation 22.
24. Conducteur impliqué dans une intersection de type "autre" (passage à niveau, place...).

6.2 Notions de changements de repère

Considérons un repère cartésien fixe $\mathcal{F} (O, {}^F \vec{i}, {}^F \vec{j})$ et un repère cartésien mobile $\mathcal{M} (E, {}^M \vec{i}, {}^M \vec{j})$ rigidement lié à l'égo-véhicule, tels que montrés sur la figure suivante.

L'objectif est de déterminer d'une part les équations de changement de repère permettant d'exprimer dans \mathcal{F} , l'état connu d'une cible C dans \mathcal{M} et d'autre part les équations de passage inverse. Soient ${}^F X_C$ l'état de la cible dans le repère \mathcal{F} et ${}^M X_C$ son état dans le repère \mathcal{M} , définis comme suit




Figure 6.1: Conversion d'état entre repère fixe et repère mobile

$${}^F X_C = \left[{}^F x_C, {}^F y_C, {}^F v_{C,x}, {}^F v_{C,y}, {}^F a_{C,x}, {}^F a_{C,y} \right]^T$$

$${}^M X_C = \left[{}^M x_C, {}^M y_C, {}^M v_{C,x}, {}^M v_{C,y}, {}^M a_{C,x}, {}^M a_{C,y} \right]^T$$

Pour les deux types de changement de repère, la position $E \left({}^F x_E, {}^F y_E \right)$, la vitesse linéaire ${}^F v_E$, l'accélération tangentielle ${}^F a_{T,E}$, la vitesse de lacet ω et l'orientation relative θ de l'égo-véhicule à un instant quelconque sont connues dans \mathcal{F} et ω est supposée constante et n'est autre que la dérivée de θ . Avant de déterminer les équations de changement de repère, définissons quelques égalités qui serviront par la suite

6.2.1 Théorèmes

La définition de la base mobile dans le repère fixe est obtenue par le système d'équations suivant

$$\begin{cases} {}^M \vec{i} &= \cos \theta {}^F \vec{i} + \sin \theta {}^F \vec{j} \\ {}^M \vec{j} &= -\sin \theta {}^F \vec{i} + \cos \theta {}^F \vec{j} \end{cases} \quad (6.1)$$

La définition de la base fixe dans le repère mobile est obtenue par le système d'équa-

tions suivant

$$\begin{cases} {}^F \vec{i} &= \cos \theta {}^M \vec{i} - \sin \theta {}^M \vec{j} \\ {}^F \vec{j} &= \sin \theta {}^M \vec{i} + \cos \theta {}^M \vec{j} \end{cases} \quad (6.2)$$

La base fixe étant constante dans \mathcal{F} , la dérivée de la base mobile dans \mathcal{F} est donnée par

$$\begin{cases} \frac{d^M \vec{i}}{dt} &= -\omega \sin \theta {}^F \vec{i} + \omega \cos \theta {}^F \vec{j} \\ \frac{d^M \vec{j}}{dt} &= -\omega \cos \theta {}^F \vec{i} - \omega \sin \theta {}^F \vec{j} \end{cases} \quad (6.3)$$

Considérons maintenant une troisième dimension k telle que le repère $\mathcal{R} (O, {}^F \vec{i}, {}^F \vec{j}, \vec{k})$ forme une base directe et définissons le vecteur vitesse de rotation $\vec{\omega}$ comme suit

$$\vec{\omega} = [0, 0, \omega]^T$$

Du système d'équations 6.3 et en notant que

$$\begin{cases} {}^M \vec{i} &= [\cos \theta, \sin \theta, 0]^T \\ {}^M \vec{j} &= [-\sin \theta, \cos \theta, 0]^T \end{cases}$$

on peut aisément vérifier que

$$\begin{cases} \frac{d^M \vec{i}}{dt} &= \vec{\omega} \wedge {}^M \vec{i} \\ \frac{d^M \vec{j}}{dt} &= \vec{\omega} \wedge {}^M \vec{j} \end{cases} \quad (6.4)$$

Pour un vecteur ${}^F \vec{V} ({}^F x, {}^F y)$ quelconque défini dans \mathcal{F} . On a

$${}^F (\vec{\omega} \wedge {}^F \vec{V}) = \omega \begin{bmatrix} -{}^F y \\ {}^F x \end{bmatrix} \quad (6.5)$$

Pour un vecteur ${}^M \vec{V} ({}^M x, {}^M y)$ quelconque défini dans \mathcal{M} . On a

$${}^F (\vec{\omega} \wedge {}^M \vec{V}) = \omega \begin{bmatrix} -{}^M x \sin \theta - {}^M y \cos \theta \\ {}^M x \cos \theta - {}^M y \sin \theta \end{bmatrix} \quad (6.6)$$

Soit ${}^F\vec{a}_E$ le vecteur accélération de l'égo-véhicule. Il est égal à la somme du vecteur accélération tangentielle ${}^F\vec{a}_{T,E}$ (tangente à l'axe de l'égo-véhicule) et du vecteur accélération normale ${}^F\vec{a}_{N,E}$ (orthogonale à l'axe de l'égo-véhicule). On peut donc écrire

$$\begin{aligned} {}^F\vec{a}_E &= {}^F a_{T,E} {}^M\vec{i} + {}^F a_{N,E} {}^M\vec{j} \\ &= {}^F a_{T,C} {}^M\vec{i} + \omega^F v_E {}^M\vec{j} \end{aligned} \quad (6.7)$$

En remplaçant ${}^M\vec{i}$ et ${}^M\vec{j}$ par leurs expressions dans la base fixe (équation 6.1) et en regroupant les termes on a

$${}^F\vec{a}_E = \left({}^F a_{T,E} \cos \theta - {}^F a_{N,E} \sin \theta \right) {}^F\vec{i} + \left({}^F a_{T,E} \sin \theta + {}^F a_{N,E} \cos \theta \right) {}^F\vec{j}$$

avec

$${}^F a_{N,E} = \omega^F v_E$$

Les composantes du vecteur accélération de l'égo-véhicule dans \mathcal{F} sont

$$\begin{cases} {}^F a_{x,E} &= {}^F a_{T,E} \cos \theta - \omega^F v_E \sin \theta \\ {}^F a_{y,E} &= {}^F a_{T,E} \sin \theta + \omega^F v_E \cos \theta \end{cases} \quad (6.8)$$

6.2.2 Transformation du repère mobile \mathcal{M} au repère fixe \mathcal{F}

Position

D'après la loi de composition des vecteurs, on peut écrire

$$\begin{aligned} \vec{OC} &= \vec{OE} + \vec{EC} \\ &= \left({}^F x_E {}^F\vec{i} + {}^F y_E {}^F\vec{j} \right) + \left({}^M x_C {}^M\vec{i} + {}^M y_C {}^M\vec{j} \right) \end{aligned}$$

En remplaçant ${}^M\vec{i}$ et ${}^M\vec{j}$ par leurs expressions dans la base fixe (équation 6.1) et en regroupant les termes, on obtient

$$\vec{OC} = \left({}^F x_E + {}^M x_C \cos \theta - {}^M y_C \sin \theta \right) {}^F\vec{i} + \left({}^F y_E + {}^M x_C \sin \theta + {}^M y_C \cos \theta \right) {}^F\vec{j}$$

d'où le résultat

$$\begin{cases} {}^F x_C &= {}^M x_C \cos \theta - {}^M y_C \sin \theta + {}^F x_E \\ {}^F y_C &= {}^M x_C \sin \theta + {}^M y_C \cos \theta + {}^F y_E \end{cases} \quad (6.9)$$

Vitesse

Soit ${}^F \vec{v}_C$ (${}^F v_{x,C}, {}^F v_{y,C}$) le vecteur vitesse connu de C dans \mathcal{F} . La vitesse étant la dérivée de la position, on peut écrire :

$${}^F \vec{v}_C = \frac{d\vec{OC}}{dt} = \frac{d\vec{OE}}{dt} + \frac{d\vec{EC}}{dt} \quad (6.10)$$

On rappelle que $\frac{d\vec{OE}}{dt}$ n'est autre que le vecteur vitesse de l'égo-véhicule dans \mathcal{F} . Il est tangent à l'axe du véhicule et donc colinéaire au vecteur ${}^M \vec{i}$. On peut alors écrire

$$\frac{d\vec{OE}}{dt} = {}^F \vec{v}_E = \begin{bmatrix} {}^F v_{x,E} \\ {}^F v_{y,E} \end{bmatrix} = \begin{bmatrix} {}^F v_E \cos \theta \\ {}^F v_E \sin \theta \end{bmatrix} \quad (6.11)$$

Calculons la dérivée du vecteur position \vec{EC} .

$$\begin{aligned} \frac{d\vec{EC}}{dt} &= \frac{d({}^M x_C {}^M \vec{i} + {}^M y_C {}^M \vec{j})}{dt} \\ &= \underbrace{\frac{d{}^M x_C}{dt} {}^M \vec{i} + \frac{d{}^M y_C}{dt} {}^M \vec{j}}_{{}^M \vec{v}_C} + {}^M x_C \frac{d{}^M \vec{i}}{dt} + {}^M y_C \frac{d{}^M \vec{j}}{dt} \end{aligned}$$

De l'équation 6.4 nous pouvons poursuivre ce développement comme ceci :

$$\begin{aligned} \frac{d\vec{EC}}{dt} &= {}^M \vec{v}_C + {}^M x_C \cdot \vec{\omega} \wedge {}^M \vec{i} + {}^M y_C \cdot \vec{\omega} \wedge {}^M \vec{j} \\ &= {}^M \vec{v}_C + \vec{\omega} \wedge ({}^M y_C \cdot {}^M \vec{i} + {}^M x_C \cdot {}^M \vec{j}) \\ &= {}^M \vec{v}_C + \vec{\omega} \wedge \vec{EC} \end{aligned} \quad (6.12)$$

$${}^F\vec{v}_C = {}^F\vec{v}_E + {}^M\vec{v}_C + \vec{\omega} \wedge \overrightarrow{EC} \quad (6.13)$$

avec

$$\begin{aligned} {}^F\vec{v}_E &= {}^Fv_{x,E} \cdot {}^F\vec{i} + {}^Fv_{y,E} \cdot {}^F\vec{j} \\ {}^M\vec{v}_C &= {}^Mv_{x,C} \cdot {}^M\vec{i} + {}^Mv_{y,C} \cdot {}^M\vec{j} \\ &= ({}^Mv_{x,C} \cos \theta - {}^Mv_{y,C} \sin \theta) {}^F\vec{i} + ({}^Mv_{x,C} \sin \theta + {}^Mv_{y,C} \cos \theta) {}^F\vec{j} \end{aligned}$$

D'après l'équation 6.5 on a

$$\vec{\omega} \wedge \overrightarrow{EC} = \omega \left(-{}^Mx_C \sin \theta - {}^My_C \cos \theta \right) {}^F\vec{i} + \omega \left({}^Mx_C \cos \theta - {}^My_C \sin \theta \right) {}^F\vec{j}$$

Pour le paramètre vitesse on obtient la transformation suivante

$$\begin{cases} {}^Fv_{x,C} &= {}^Fv_{x,E} + \left({}^Mv_{x,C} \cos \theta - {}^Mv_{y,C} \sin \theta \right) - \omega \left({}^Mx_C \sin \theta + {}^My_C \cos \theta \right) \\ {}^Fv_{y,C} &= {}^Fv_{y,E} + \left({}^Mv_{x,C} \sin \theta + {}^Mv_{y,C} \cos \theta \right) + \omega \left({}^Mx_C \cos \theta - {}^My_C \sin \theta \right) \end{cases} \quad (6.14)$$

avec

$$\begin{cases} {}^Fv_{x,E} &= {}^Fv_E \cos \theta \\ {}^Fv_{y,E} &= {}^Fv_E \sin \theta \end{cases}$$

Accélération

Soit ${}^F\vec{a}_C$ (${}^Fa_{x,C}$, ${}^Fa_{y,C}$) le vecteur accélération de C dans \mathcal{F} . Le vecteur accélération est la somme du vecteur accélération tangentielle est du vecteur accélération normale. Le vecteur accélération étant la dérivée du vecteur vitesse et considérant l'équation 6.13, on peut écrire :

$${}^F\vec{a}_C = \frac{d{}^F\vec{v}_C}{dt} = \underbrace{\frac{d{}^F\vec{v}_E}{dt}}_{{}^F\vec{a}_E} + \frac{d{}^M\vec{v}_C}{dt} + \frac{d(\vec{\omega} \wedge \overrightarrow{EC})}{dt} \quad (6.15)$$

Rappelons que par définition

$${}^M\vec{v}_C = \frac{d{}^Mx_C}{dt} {}^M\vec{i} + \frac{d{}^My_C}{dt} {}^M\vec{j}$$

En dérivant cette expression, on obtient

$$\frac{d^M \vec{v}_C}{dt} = \underbrace{\frac{d^{2M} x_C}{dt} M \vec{i} + \frac{d^{2M} y_C}{dt} M \vec{j}}_{M \vec{a}_C} + \underbrace{\frac{d^M x_C}{dt}}_{M v_{x,C}} \frac{d^M \vec{i}}{dt} + \underbrace{\frac{d^M y_C}{dt}}_{M v_{y,C}} \frac{d^M \vec{j}}{dt}$$

D'après l'équation 6.4, cette égalité devient

$$\begin{aligned} \frac{d^M \vec{v}_C}{dt} &= M \vec{a}_C + M v_{x,C} \cdot \vec{\omega} \wedge M \vec{i} + M v_{y,C} \cdot \vec{\omega} \wedge M \vec{j} \\ &= M \vec{a}_C + \vec{\omega} \wedge (M v_{x,C} \cdot M \vec{i} + M v_{y,C} \cdot M \vec{j}) \\ &= M \vec{a}_C + \vec{\omega} \wedge M \vec{v}_C \end{aligned} \quad (6.16)$$

On a

$$\frac{d(\vec{\omega} \wedge \overrightarrow{EC})}{dt} = \frac{d\vec{\omega}}{dt} \wedge \overrightarrow{EC} + \vec{\omega} \wedge \frac{d\overrightarrow{EC}}{dt}$$

Or, ω est une constante et on rappelle d'après l'équation 6.12 que

$$\frac{d\overrightarrow{EC}}{dt} = M \vec{v}_C + \vec{\omega} \wedge \overrightarrow{EC}$$

Donc

$$\frac{d(\vec{\omega} \wedge \overrightarrow{EC})}{dt} = \vec{0} + \vec{\omega} \wedge M \vec{v}_C + \vec{\omega} \wedge (\vec{\omega} \wedge \overrightarrow{EC}) \quad (6.17)$$

Des équations 6.16 et 6.17, on poursuit le développement de l'équation 6.15 comme ceci

$$\begin{aligned} F \vec{a}_C &= F \vec{a}_E + (M \vec{a}_C + \vec{\omega} \wedge M \vec{v}_C) + (\vec{\omega} \wedge M \vec{v}_C + \vec{\omega} \wedge (\vec{\omega} \wedge \overrightarrow{EC})) \\ &= F \vec{a}_E + M \vec{a}_C + 2 \cdot \vec{\omega} \wedge M \vec{v}_C + \vec{\omega} \wedge (\vec{\omega} \wedge \overrightarrow{EC}) \end{aligned} \quad (6.18)$$

avec

$$F \vec{a}_E = F a_{x,E} F \vec{i} + F a_{y,E} F \vec{j}$$

où $F a_{x,E}$ et $F a_{y,E}$ sont déterminées grâce à l'équation 6.8.

$$\begin{aligned} {}^M \vec{a}_C &= {}^M a_{x,C} \cdot {}^M \vec{i} + {}^M a_{y,C} \cdot {}^M \vec{j} \\ &= ({}^M a_{x,C} \cos \theta - {}^M a_{y,C} \sin \theta) {}^F \vec{i} + ({}^M a_{x,C} \sin \theta + {}^M a_{y,C} \cos \theta) {}^F \vec{j} \end{aligned}$$

Des équations 6.5 et 6.6, on a

$$\begin{aligned} \vec{\omega} \wedge {}^M \vec{v}_C &= \omega \left(-{}^M v_{x,C} \sin \theta - {}^M v_{y,C} \cos \theta \right) {}^F \vec{i} + \omega \left({}^M v_{x,C} \cos \theta - {}^M v_{y,C} \sin \theta \right) {}^F \vec{j} \\ \vec{\omega} \wedge \left(\vec{\omega} \wedge \vec{EC} \right) &= \omega^2 \left({}^M y_C \sin \theta - {}^M x_C \cos \theta \right) {}^F \vec{i} - \omega^2 \left({}^M x_C \sin \theta + {}^M y_C \cos \theta \right) {}^F \vec{j} \end{aligned}$$

Pour le paramètre accélération on obtient la transformation suivante

$$\begin{cases} {}^F a_{x,C} &= {}^F a_{x,E} + {}^M a_{x,C} \cos \theta - {}^M a_{y,C} \sin \theta - \\ &2\omega \left({}^M v_{x,C} \sin \theta + {}^M v_{y,C} \cos \theta \right) + \omega^2 \left({}^M y_C \sin \theta - {}^M x_C \cos \theta \right) \\ {}^F a_{y,C} &= {}^F a_{y,E} + {}^M a_{x,C} \sin \theta + {}^M a_{y,C} \cos \theta + \\ &2\omega \left({}^M v_{x,C} \cos \theta - {}^M v_{y,C} \sin \theta \right) - \omega^2 \left({}^M x_C \sin \theta + {}^M y_C \cos \theta \right) \end{cases}$$

Synthèse

Le passage du repère mobile au repère fixe se fait grâce aux équations suivantes

$${}^F X_C = \begin{cases} {}^F x_C &= {}^M x_C \cos \theta - {}^M y_C \sin \theta + {}^F x_E \\ {}^F y_C &= {}^M x_C \sin \theta + {}^M y_C \cos \theta + {}^F y_E \\ {}^F v_{x,C} &= {}^F v_{x,E} + \left({}^M v_{x,C} \cos \theta - {}^M v_{y,C} \sin \theta \right) - \omega \left({}^M x_C \sin \theta + {}^M y_C \cos \theta \right) \\ {}^F v_{y,C} &= {}^F v_{y,E} + \left({}^M v_{x,C} \sin \theta + {}^M v_{y,C} \cos \theta \right) + \omega \left({}^M x_C \cos \theta - {}^M y_C \sin \theta \right) \\ {}^F a_{x,C} &= {}^F a_{x,E} + \left({}^M a_{x,C} \cos \theta - {}^M a_{y,C} \sin \theta \right) - \\ &2\omega \left({}^M v_{x,C} \sin \theta + {}^M v_{y,C} \cos \theta \right) + \omega^2 \left({}^M y_C \sin \theta - {}^M x_C \cos \theta \right) \\ {}^F a_{y,C} &= {}^F a_{y,E} + \left({}^M a_{x,C} \sin \theta + {}^M a_{y,C} \cos \theta \right) + \\ &2\omega \left({}^M v_{x,C} \cos \theta - {}^M v_{y,C} \sin \theta \right) - \omega^2 \left({}^M x_C \sin \theta + {}^M y_C \cos \theta \right) \end{cases} \quad (6.19)$$

avec

$$\begin{cases} {}^F v_{x,E} &= {}^F v_E \cos \theta \\ {}^F v_{y,E} &= {}^F v_E \sin \theta \\ {}^F a_{x,E} &= {}^F a_{T,E} \cos \theta - \omega {}^F v_E \sin \theta \\ {}^F a_{y,E} &= {}^F a_{T,E} \sin \theta + \omega {}^F v_E \cos \theta \end{cases}$$

Si $\omega = 0$, on obtient

$${}^F X_C = \begin{cases} {}^F x_C &= {}^M x_C \cos \theta - {}^M y_C \sin \theta + {}^F x_E \\ {}^F y_C &= {}^M x_C \sin \theta + {}^M y_C \cos \theta + {}^F y_E \\ {}^F v_{x,C} &= {}^F v_{x,E} + {}^M v_{x,C} \cos \theta - {}^M v_{y,C} \sin \theta \\ {}^F v_{y,C} &= {}^F v_{y,E} + {}^M v_{x,C} \sin \theta + {}^M v_{y,C} \cos \theta \\ {}^F a_{x,C} &= {}^F a_{x,E} + {}^M a_{x,C} \cos \theta - {}^M a_{y,C} \sin \theta \\ {}^F a_{y,C} &= {}^F a_{y,E} + {}^M a_{x,C} \sin \theta + {}^M a_{y,C} \cos \theta \end{cases} \quad (6.20)$$

avec

$$\begin{cases} {}^F v_{x,E} &= {}^F v_E \cos \theta \\ {}^F v_{y,E} &= {}^F v_E \sin \theta \\ {}^F a_{x,E} &= {}^F a_{T,E} \cos \theta \\ {}^F a_{y,E} &= {}^F a_{T,E} \sin \theta \end{cases}$$

6.2.3 Transformation du repère fixe \mathcal{F} au repère mobile \mathcal{M}

Cette fois-ci, ${}^F X_C$ est connu et nous cherchons à déterminer ${}^M X_C$

Position

En considérant les coordonnées du vecteur \overrightarrow{EC} dans \mathcal{F} , on peut écrire

$$\overrightarrow{EC} = ({}^F x_C - {}^F x_E) {}^F \vec{i} + ({}^F y_C - {}^F y_E) {}^F \vec{j}$$

En remplaçant ${}^F \vec{i}$ et ${}^F \vec{j}$ par leurs expressions dans la base mobile (équation 6.2) et en regroupant les termes, on obtient

$$\begin{aligned} \overrightarrow{EC} = & \left(({}^F x_C - {}^F x_E) \cos \theta + ({}^F y_C - {}^F y_E) \sin \theta \right) {}^M \vec{i} + \\ & \left(- ({}^F x_C - {}^F x_E) \sin \theta + ({}^F y_C - {}^F y_E) \cos \theta \right) {}^M \vec{j} \end{aligned}$$

d'où le résultat

$$\begin{cases} {}^M x_C &= ({}^F x_C - {}^F x_E) \cos \theta + ({}^F y_C - {}^F y_E) \sin \theta \\ {}^M y_C &= - ({}^F x_C - {}^F x_E) \sin \theta + ({}^F y_C - {}^F y_E) \cos \theta \end{cases} \quad (6.21)$$

Vitesse

Partons du résultat de l'équation 6.13 :

$${}^F \vec{v}_C = {}^F \vec{v}_E + {}^M \vec{v}_C + \vec{\omega} \wedge \overrightarrow{EC}$$

On en déduit

$${}^M \vec{v}_C = {}^F \vec{v}_C - {}^F \vec{v}_E - \vec{\omega} \wedge \overrightarrow{EC}$$

avec

$$\begin{aligned} {}^F \vec{v}_C &= {}^F v_{x,C} {}^F \vec{i} + {}^F v_{y,C} {}^F \vec{j} \\ &= \left({}^F v_{x,C} \cos \theta + {}^F v_{y,C} \sin \theta \right) {}^M \vec{i} + \left(-{}^F v_{x,C} \sin \theta + {}^F v_{y,C} \cos \theta \right) {}^M \vec{j} \end{aligned}$$

Puisque le vecteur vitesse de l'égo-véhicule est tangent à l'axe du véhicule, on a

$${}^F \vec{v}_E = {}^F v_E {}^M \vec{i}$$

Grâce à l'expression de \overrightarrow{EC} dans le repère mobile (équation 6.21) et à la règle de l'équation 6.6, on obtient

$$\begin{aligned} \vec{\omega} \wedge \overrightarrow{EC} &= \omega \left(({}^F x_C - {}^F x_E) \sin \theta - ({}^F y_C - {}^F y_E) \cos \theta \right) {}^M \vec{i} + \\ &\quad \omega \left(({}^F x_C - {}^F x_E) \cos \theta + ({}^F y_C - {}^F y_E) \sin \theta \right) {}^M \vec{j} \end{aligned}$$

Les composantes de ${}^M\vec{v}_C$ dans le repère mobile donnent donc

$$\begin{cases} {}^M v_{x,C} &= {}^F v_{x,C} \cos \theta - {}^F v_E + {}^F v_{y,C} \sin \theta - \\ &\quad \omega \left(({}^F x_C - {}^F x_E) \sin \theta - ({}^F y_C - {}^F y_E) \cos \theta \right) \\ {}^M v_{y,C} &= -{}^F v_{x,C} \sin \theta + {}^F v_{y,C} \cos \theta - \\ &\quad \omega \left(({}^F x_C - {}^F x_E) \cos \theta + ({}^F y_C - {}^F y_E) \sin \theta \right) \end{cases} \quad (6.22)$$

Accélération

Partons du résultat de l'équation 6.18 :

$${}^F \vec{a}_C = {}^F \vec{a}_E + {}^M \vec{a}_C + 2 \cdot \vec{\omega} \wedge {}^M \vec{v}_C + \vec{\omega} \wedge (\vec{\omega} \wedge \vec{EC})$$

On en déduit que

$${}^M \vec{a}_C = {}^F \vec{a}_C - {}^F \vec{a}_E - 2 \cdot \vec{\omega} \wedge {}^M \vec{v}_C - \vec{\omega} \wedge (\vec{\omega} \wedge \vec{EC})$$

avec

$$\begin{aligned} {}^F \vec{a}_C &= {}^F a_{x,C} {}^F \vec{i} + {}^F a_{y,C} {}^F \vec{j} \\ &= ({}^F a_{x,C} \cos \theta + {}^F a_{y,C} \sin \theta) {}^M \vec{i} + (-{}^F a_{x,C} \sin \theta + {}^F a_{y,C} \cos \theta) {}^M \vec{j} \end{aligned}$$

De l'équation 6.7, on a

$${}^F \vec{a}_E = {}^F a_{T,E} {}^M \vec{i} + \omega {}^F v_E {}^M \vec{j}$$

D'après la règle de l'équation 6.6 et connaissant ${}^M \vec{v}_C$ (équation 6.22) on a

$$\begin{aligned} \vec{\omega} \wedge {}^M \vec{v}_C &= \left(\omega \left({}^F v_{x,C} \sin \theta - {}^F v_{y,C} \cos \theta \right) + \right. \\ &\quad \left. \omega^2 \left(({}^F x_C - {}^F x_E) \cos \theta + ({}^F y_C - {}^F y_E) \sin \theta \right) \right) {}^M \vec{i} + \\ &\quad \left(\omega \left({}^F v_{x,C} \cos \theta - {}^F v_E + {}^F v_{y,C} \sin \theta \right) - \right. \\ &\quad \left. \omega^2 \left(({}^F x_C - {}^F x_E) \sin \theta - ({}^F y_C - {}^F y_E) \cos \theta \right) \right) {}^M \vec{j} \end{aligned}$$

D'après la règle de l'équation 6.6 et connaissant l'expression de \vec{EC} dans le repère

mobile (équation 6.21), on a

$$\vec{\omega} \wedge (\vec{\omega} \wedge \overrightarrow{EC}) = -\omega^2 \left(({}^F x_C - {}^F x_E) \cos \theta + ({}^F y_C - {}^F y_E) \sin \theta \right) M \vec{i} + \omega^2 \left(({}^F x_C - {}^F x_E) \sin \theta - ({}^F y_C - {}^F y_E) \cos \theta \right) M \vec{j}$$

Les composantes de ${}^M \vec{a}_C$ dans le repère mobile donnent donc

$$\begin{cases} {}^M a_{x,C} &= {}^F a_{x,C} \cos \theta - {}^F a_{T,E} + {}^F a_{y,C} \sin \theta - 2\omega ({}^F v_{x,C} \sin \theta - {}^F v_{y,C} \cos \theta) - \\ &\quad \omega^2 \left(({}^F x_C - {}^F x_E) \cos \theta + ({}^F y_C - {}^F y_E) \sin \theta \right) \\ {}^M a_{y,C} &= -{}^F a_{x,C} \sin \theta + {}^F a_{y,C} \cos \theta - \omega {}^F v_E - 2\omega ({}^F v_{x,C} \cos \theta - {}^F v_E + {}^F v_{y,C} \sin \theta) + \\ &\quad \omega^2 \left(({}^F x_C - {}^F x_E) \sin \theta - ({}^F y_C - {}^F y_E) \cos \theta \right) \end{cases}$$

Synthèse

Le changement du repère fixe au repère mobile se fait grâce aux équations suivantes

$${}^M X_C = \begin{cases} {}^M x_C &= ({}^F x_C - {}^F x_E) \cos \theta + ({}^F y_C - {}^F y_E) \sin \theta \\ {}^M y_C &= - ({}^F x_C - {}^F x_E) \sin \theta + ({}^F y_C - {}^F y_E) \cos \theta \\ {}^M v_{x,C} &= {}^F v_{x,C} \cos \theta - {}^F v_E + {}^F v_{y,C} \sin \theta - \\ &\quad \omega \left(({}^F x_C - {}^F x_E) \sin \theta - ({}^F y_C - {}^F y_E) \cos \theta \right) \\ {}^M v_{y,C} &= -{}^F v_{x,C} \sin \theta + {}^F v_{y,C} \cos \theta - \\ &\quad \omega \left(({}^F x_C - {}^F x_E) \cos \theta + ({}^F y_C - {}^F y_E) \sin \theta \right) \\ {}^M a_{x,C} &= {}^F a_{x,C} \cos \theta - {}^F a_{T,E} + {}^F a_{y,C} \sin \theta - 2\omega ({}^F v_{x,C} \sin \theta - {}^F v_{y,C} \cos \theta) - \\ &\quad \omega^2 \left(({}^F x_C - {}^F x_E) \cos \theta + ({}^F y_C - {}^F y_E) \sin \theta \right) \\ {}^M a_{y,C} &= -{}^F a_{x,C} \sin \theta + {}^F a_{y,C} \cos \theta - \omega {}^F v_E - 2\omega ({}^F v_{x,C} \cos \theta - {}^F v_E + {}^F v_{y,C} \sin \theta) + \\ &\quad \omega^2 \left(({}^F x_C - {}^F x_E) \sin \theta - ({}^F y_C - {}^F y_E) \cos \theta \right) \end{cases} \quad (6.23)$$

Si $\omega = 0$, on obtient

$${}^M X_C = \begin{cases} {}^M x_C &= ({}^F x_C - {}^F x_E) \cos \theta + ({}^F y_C - {}^F y_E) \sin \theta \\ {}^M y_C &= - ({}^F x_C - {}^F x_E) \sin \theta + ({}^F y_C - {}^F y_E) \cos \theta \\ {}^M v_{x,C} &= {}^F v_{x,C} \cos \theta - {}^F v_E + {}^F v_{y,C} \sin \theta \\ {}^M v_{y,C} &= -{}^F v_{x,C} \sin \theta + {}^F v_{y,C} \cos \theta \\ {}^M a_{x,C} &= {}^F a_{x,C} \cos \theta - {}^F a_{T,E} + {}^F a_{y,C} \sin \theta \\ {}^M a_{y,C} &= -{}^F a_{x,C} \sin \theta + {}^F a_{y,C} \cos \theta \end{cases} \quad (6.24)$$

6.3 Équations d'un modèle de mouvement à vitesse de lacet et à accélération tangentielle constantes

On considère un objet dont l'état à un instant t est noté

$$X = [x, y, \theta, v, a, \omega]^T$$

où (x, y) représente la position de l'objet dans le repère cartésien considéré, θ son angle de lacet, v sa vitesse linéaire, a son accélération tangentielle et ω sa vitesse de lacet.

Par définition, a et ω sont constantes et leurs valeurs initiales sont respectivement notées a_0 et ω_0 . Soient v_0 vitesse linéaire initiale et θ_0 le lacet initial. La vitesse linéaire et le lacet sont respectivement obtenus en fonction du temps par

$$\begin{cases} v(t) &= v_0 + a_0 t \\ \theta(t) &= \theta_0 + \omega_0 t \end{cases}$$

En considérant la vitesse suivant chaque dimension du repère on a

$$\begin{cases} v_x(t) &= (v_0 + a_0 \cdot t) \cos(\theta_0 + \omega_0 t) \\ v_y(t) &= (v_0 + a_0 \cdot t) \sin(\theta_0 + \omega_0 t) \end{cases}$$

Soit (x_0, y_0) la position initiale. En intégrant la vitesse suivant chaque dimension on obtient la position de l'objet :

$$\begin{aligned} x(t) &= \int (v_0 + a_0 \cdot t) \cos(\theta_0 + \omega_0 t) dt \\ &= v_0 \int \cos(\theta_0 + \omega_0 t) dt + a_0 \int t \cos(\theta_0 + \omega_0 t) dt \\ &= \frac{v_0}{\omega_0} \sin(\theta_0 + \omega_0 t) + a_0 \left(\frac{t}{\omega_0} \sin(\theta_0 + \omega_0 t) + \frac{1}{\omega_0^2} \cos(\theta_0 + \omega_0 t) \right) + c_x \\ &= \frac{a_0}{\omega_0^2} \cos(\theta_0 + \omega_0 t) + \frac{v_0 + a_0 t}{\omega_0} \sin(\theta_0 + \omega_0 t) + c_x \end{aligned}$$

avec $\omega_0 \neq 0$ et c_x une constante définie grâce aux conditions initiales $x(0) = x_0$. On obtient

$$c_x = x_0 - \frac{v_0}{\omega_0} \sin(\theta_0) - \frac{a_0}{\omega_0^2} \cos(\theta_0)$$

De façon analogue, on détermine

$$y(t) = \frac{a_0}{\omega_0^2} \sin(\theta_0 + \omega_0 t) - \frac{v_0 + a_0 t}{\omega_0} \cos(\theta_0 + \omega_0 t) + c_y$$

avec

$$c_y = y_0 + \frac{v_0}{\omega_0} \cos(\theta_0) - \frac{a_0}{\omega_0^2} \sin(\theta_0)$$

Les équations du mouvement dans le domaine continu se résument par :

$$X(t) : \begin{cases} x(t) &= c_x + \frac{a_0}{\omega_0^2} \cos(\theta_0 + \omega t) + \frac{v_0 + a_0 t}{\omega_0} \sin(\theta_0 + \omega_0 t) \\ y(t) &= c_y + \frac{a_0}{\omega_0^2} \sin(\theta_0 + \omega_0 t) - \frac{v_0 + a_0 t}{\omega_0} \cos(\theta_0 + \omega_0 t) \\ \theta(t) &= \theta_0 + \omega_0 t \\ v(t) &= v_0 + a_0 t \\ a(t) &= a_0 \\ \omega(t) &= \omega_0 \end{cases} \quad (6.25)$$

avec $\omega_0 \neq 0$ et

$$\begin{cases} c_x &= x_0 - \frac{v_0}{\omega_0} \sin(\theta_0) - \frac{a_0}{\omega_0^2} \cos(\theta_0) \\ c_y &= y_0 + \frac{v_0}{\omega_0} \cos(\theta_0) - \frac{a_0}{\omega_0^2} \sin(\theta_0) \end{cases}$$

Pour $\omega_0 = 0$ on obtient

$$X(t) : \begin{cases} x(t) &= x_0 + \left(v_0 t + \frac{1}{2} \cdot a_0 t^2 \right) \cos(\theta_0) \\ y(t) &= y_0 + \left(v_0 t + \frac{1}{2} \cdot a_0 t^2 \right) \sin(\theta_0) \\ \theta(t) &= \theta_0 \\ v(t) &= v_0 + a_0 t \\ a(t) &= a_0 \\ \omega(t) &= 0 \end{cases} \quad (6.26)$$

Dans le domaine discret, considérons l'état $X_k = [x_k, y_k, \theta_k, v_k, a_k, \omega_k]^T$ d'un objet à

l'instant t_k et notons $T_e = t_{k+1} - t_k$. L'état X_{k+1} de l'objet à l'instant t_{k+1} est donné par

$$X_{k+1} : \begin{cases} x_{k+1} &= x_k + \frac{a_k}{\omega_k^2} \cos(\theta_k + \omega_k T_e) + \frac{v_k + a_k T_e}{\omega_k} \sin(\theta_k + \omega_k T_e) + c_x \\ y_{k+1} &= y_k + \frac{a_k}{\omega_k^2} \sin(\theta_k + \omega_k T_e) - \frac{v_k + a_k T_e}{\omega_k} \cos(\theta_k + \omega_k T_e) + c_y \\ \theta_{k+1} &= \theta_k + \omega_k T_e \\ v_{k+1} &= v_k + a_k T_e \\ a_{k+1} &= a_k \\ \omega_{k+1} &= \omega_k \end{cases} \quad (6.27)$$

avec $\omega_k \neq 0$ et

$$\begin{cases} c_x &= \frac{v_k}{\omega_k} \sin(\theta_k) - \frac{a_k}{\omega_k^2} \cos(\theta_k) \\ c_y &= \frac{v_k}{\omega_k} \cos(\theta_k) - \frac{a_k}{\omega_k^2} \sin(\theta_k) \end{cases}$$

Pour $\omega_k = 0$, on obtient

$$X_{k+1} : \begin{cases} x_{k+1} &= x_k + \left(v_k T_e + \frac{1}{2} \cdot a_k T_e^2 \right) \cos(\theta_k) \\ y_{k+1} &= y_k + \left(v_k T_e + \frac{1}{2} \cdot a_k T_e^2 \right) \sin(\theta_k) \\ \theta_{k+1} &= \theta_k \\ v_{k+1} &= v_k + a_k T_e \\ a_{k+1} &= a_k \\ \omega_{k+1} &= 0 \end{cases} \quad (6.28)$$

6.4 Modèles cinématiques dans un repère égo-centré

6.4.1 Modélisation du mouvement de l'égo-véhicule

Considérons un égo-véhicule noté E dont la vitesse linéaire v^* , l'accélération tangentielle a^* et la vitesse de lacet ω sont mesurées grâce à des capteurs proprioceptifs. a^* et ω sont supposées constantes sur une période d'échantillonnage. Soit un repère $\mathcal{R}(E, \vec{i}, \vec{j})$ lié à l'égo-véhicule. Considérons le mouvement du véhicule entre un instant t_k et un instant t_{k+1} comme montré sur la figure 6.2.

Déterminons la pose du repère $\mathcal{R}_{k+1}(E_{k+1}, \vec{i}_{k+1}, \vec{j}_{k+1})$ dans le repère $\mathcal{R}_k(E_k, \vec{i}_k, \vec{j}_k)$. Considérons l'expression du modèle cinématique d'un mouvement à vitesse de lacet




Figure 6.2: Mouvement de l'égo-véhicule

et accélération tangentielle constante (équation 6.27) dans la section 6.3. Par rapport à notre nouveau contexte, on a

$$\begin{cases} x_k &= 0 \\ y_k &= 0 \\ \theta_k &= 0 \\ v_k &= v^* \\ a_k &= a^* \\ \omega_k &= \omega^* \end{cases}$$

On en déduit les égalités suivantes pour la position et l'orientation relatives

$$\begin{cases} \tilde{x} &= \frac{a^*}{\omega^{*2}} \cos(\omega^* T_e) + \frac{v^* + a^* T_e}{\omega^*} \sin(\omega^* T_e) - \frac{a^*}{\omega^{*2}} \\ \tilde{y} &= \frac{a^*}{\omega^{*2}} \sin(\omega^* T_e) - \frac{v^* + a^* T_e}{\omega^*} \cos(\omega^* T_e) + \frac{v^*}{\omega^*} \\ \tilde{\theta} &= \omega^* T_e \end{cases}$$

Le vecteur vitesse relative de E_{k+1} par rapport à E_k est la différence de leurs vecteurs vitesse par rapport au sol et on rappelle que le vecteur vitesse est toujours tangent à l'axe du véhicule. On a

$$\begin{aligned} \vec{v} &= \vec{v}_{E,k+1} - \vec{v}_{E,k} \\ &= (v^* + a^* T_e) \begin{bmatrix} \cos(\omega^* T_e) \\ \sin(\omega^* T_e) \end{bmatrix} - \begin{bmatrix} v^* \\ 0 \end{bmatrix} \\ &= \begin{bmatrix} (v^* + a^* T_e) \cos(\omega^* T_e) - v^* \\ (v^* + a^* T_e) \sin(\omega^* T_e) \end{bmatrix} \end{aligned}$$

La vitesse linéaire relative est la norme du vecteur vitesse relative. On obtient

$$\tilde{v} = \sqrt{\tilde{v}_x^2 + \tilde{v}_y^2}$$

avec

$$\begin{cases} \tilde{v}_x &= (v^* + a^*T_e) \cos(\omega^*T_e) - v^* \\ \tilde{v}_y &= (v^* + a^*T_e) \sin(\omega^*T_e) \end{cases}$$

Le vecteur accélération relative de E_{k+1} par rapport à E_k est la différence de leurs vecteurs accélération par rapport au sol et on rappelle que le vecteur accélération est la somme du vecteur accélération tangentielle (tangente à l'axe du véhicule) et du vecteur accélération normale (perpendiculaire à l'axe du véhicule). On a

$$\vec{a} = \overrightarrow{a_{E,k+1}} - \overrightarrow{a_{E,k}}$$

avec

$$\begin{aligned} \overrightarrow{a_{E,k+1}} &= \overrightarrow{a_{N,E,k+1}} + \overrightarrow{a_{T,E,k+1}} \\ &= (v^* + a^*T_e) \omega^* \begin{bmatrix} -\sin(\omega^*T_e) \\ \cos(\omega^*T_e) \end{bmatrix} + a^* \begin{bmatrix} \cos(\omega^*T_e) \\ \sin(\omega^*T_e) \end{bmatrix} \end{aligned}$$

et

$$\begin{aligned} \overrightarrow{a_{E,k}} &= \overrightarrow{a_{N,E,k}} + \overrightarrow{a_{T,E,k}} \\ &= \begin{bmatrix} 0 \\ v^*\omega^* \end{bmatrix} + \begin{bmatrix} a^* \\ 0 \end{bmatrix} \end{aligned}$$

On obtient

$$\vec{a} = \begin{cases} \tilde{a}_x &= -(v^* + a^*T_e) \omega^* \sin(\omega^*T_e) + a^* \cos(\omega^*T_e) - a^* \\ \tilde{a}_y &= (v^* + a^*T_e) \omega^* \cos(\omega^*T_e) + a^* \sin(\omega^*T_e) - v^*\omega^* \end{cases}$$

Notons que par rapport au sol, les deux repères ont la même vitesse de lacet donc leur vitesse de lacet relative est nulle ($\tilde{\omega} = 0$) et par conséquent l'accélération normale relative est nulle. Donc l'accélération tangentielle relative est égale à la norme du vecteur accélération relative :

$$\tilde{a}_T = \sqrt{\tilde{a}_x^2 + \tilde{a}_y^2}$$

En résumé on a

$$\begin{cases} \tilde{x} &= \frac{a^*}{\omega^{*2}} \cos(\omega^* T_e) + \frac{v^* + a^* T_e}{\omega^*} \sin(\omega^* T_e) - \frac{a^*}{\omega^{*2}} \\ \tilde{y} &= \frac{a^*}{\omega^{*2}} \sin(\omega^* T_e) - \frac{v^* + a^* T_e}{\omega^*} \cos(\omega^* T_e) + \frac{v^*}{\omega^*} \\ \tilde{\theta} &= \omega^* T_e \\ \tilde{v} &= \sqrt{\tilde{v}_x^2 + \tilde{v}_y^2} \\ \tilde{a}_T &= \sqrt{\tilde{a}_x^2 + \tilde{a}_y^2} \\ \tilde{\omega} &= 0 \end{cases} \quad (6.29)$$

avec

$$\begin{cases} \tilde{v}_x &= (v^* + a^* T_e) \cos(\omega^* T_e) - v^* \\ \tilde{v}_y &= (v^* + a^* T_e) \sin(\omega^* T_e) \\ \tilde{a}_x &= -(v^* + a^* T_e) \omega^* \sin(\omega^* T_e) + a^* \cos(\omega^* T_e) - a^* \\ \tilde{a}_y &= (v^* + a^* T_e) \omega^* \cos(\omega^* T_e) + a^* \sin(\omega^* T_e) - v^* \omega^* \end{cases}$$

Si $\omega^* = 0$, on obtient les égalités suivantes :

$$\begin{cases} \tilde{x} &= v^* T_e + \frac{1}{2} \cdot a^* T_e^2 \\ \tilde{y} &= 0 \\ \tilde{\theta} &= 0 \\ \tilde{v} &= a^* T_e \\ \tilde{a}_T &= 0 \\ \tilde{\omega} &= 0 \end{cases} \quad (6.30)$$

6.4.2 Modèle cinématique

Considérons maintenant un objet-cible C ayant un mouvement linéaire à accélération constante par rapport au sol. Soit $X_k = [x_k, y_k, v_{x,k}, v_{y,k}, a_{x,k}, a_{y,k}]^T$ son état mesuré dans le repère $\mathcal{R}_k (\vec{E}_k, \vec{i}_k, \vec{j}_k)$. L'objectif est de prédire son état X_{k+1} dans le futur repère $\mathcal{R}_{k+1} (\vec{E}_{k+1}, \vec{i}_{k+1}, \vec{j}_{k+1})$. Pour cela, on définit un état intermédiaire ${}^k X_{k+1}$ qui est son état prédit dans le repère \mathcal{R}_k , puis on fait un changement de repère de ${}^k X_{k+1}$ vers le repère \mathcal{R}_{k+1} .

L'équation du mouvement dans le repère \mathcal{R}_k se définit comme ceci

$${}^k X_{k+1} = \begin{cases} {}^k x_{k+1} &= x_k + v_{x,k} T_e + \frac{1}{2} a_{x,k} T_e^2 \\ {}^k y_{k+1} &= y_k + v_{y,k} T_e + \frac{1}{2} a_{y,k} T_e^2 \\ {}^k v_{x,k+1} &= v_{x,k} + a_{x,k} T_e \\ {}^k v_{y,k+1} &= v_{y,k} + a_{y,k} T_e \\ {}^k a_{x,k+1} &= a_{x,k} \\ {}^k a_{y,k+1} &= a_{y,k} \end{cases} \quad (6.31)$$

Dans la section 6.2.3, nous avons décrit le changement de repère d'un repère \mathcal{F} vers un repère \mathcal{M} où on connaît la définition de \mathcal{M} par rapport \mathcal{F} . Dans ce cas-ci, \mathcal{R}_k est analogue à \mathcal{F} et \mathcal{R}_{k+1} est analogue à \mathcal{M} . Le système d'équations 6.29 donne la définition de \mathcal{R}_{k+1} par rapport \mathcal{R}_k . La vitesse de lacet relative des deux repères $\tilde{\omega}$ étant nulle, nous utilisons l'équation 6.24 pour faire le changement de repère. Ainsi on a d'abord

$$X_{k+1} = \begin{cases} x_{k+1} &= ({}^k x_{k+1} - \tilde{x}) \cos \tilde{\theta} + ({}^k y_{k+1} - \tilde{y}) \sin \tilde{\theta} \\ y_{k+1} &= -({}^k x_{k+1} - \tilde{x}) \sin \tilde{\theta} + ({}^k y_{k+1} - \tilde{y}) \cos \tilde{\theta} \\ v_{x,k+1} &= {}^k v_{x,k+1} \cos \tilde{\theta} - \tilde{v} + {}^k v_{y,k+1} \sin \tilde{\theta} \\ v_{y,k+1} &= -{}^k v_{x,k+1} \sin \tilde{\theta} + {}^k v_{y,k+1} \cos \tilde{\theta} \\ a_{x,k+1} &= {}^k a_{x,k+1} \cos \tilde{\theta} - \tilde{a}_T + {}^k a_{y,k+1} \sin \tilde{\theta} \\ a_{y,k+1} &= -{}^k a_{x,k+1} \sin \tilde{\theta} + {}^k a_{y,k+1} \cos \tilde{\theta} \end{cases}$$

En remplaçant les paramètres de l'état intermédiaire par leurs expressions définies dans l'équation 6.31 et certains des paramètres relatifs (par souci de clarté) par leurs expressions définies dans l'équation 6.29, on obtient

$$X_{k+1} = \begin{cases} x_{k+1} &= \left(x_k + v_{x,k} T_e + \frac{1}{2} a_{x,k} T_e^2 - \frac{a^*}{\omega^{*2}} \cos \tilde{\theta} - \frac{v^* + a^* T_e}{\omega^*} \sin \tilde{\theta} + \frac{a^*}{\omega^{*2}} \right) \cos \tilde{\theta} + \\ &\quad \left(y_k + v_{y,k} T_e + \frac{1}{2} a_{y,k} T_e^2 - \frac{a^*}{\omega^{*2}} \sin \tilde{\theta} + \frac{v^* + a^* T_e}{\omega^*} \cos (\omega^* T_e) - \frac{v^*}{\omega^*} \right) \sin \tilde{\theta} \\ y_{k+1} &= - \left(x_k + v_{x,k} T_e + \frac{1}{2} a_{x,k} T_e^2 - \frac{a^*}{\omega^{*2}} \cos \tilde{\theta} - \frac{v^* + a^* T_e}{\omega^*} \sin (\omega^* T_e) + \frac{a^*}{\omega^{*2}} \right) \sin \tilde{\theta} + \\ &\quad \left(y_k + v_{y,k} T_e + \frac{1}{2} a_{y,k} T_e^2 - \frac{a^*}{\omega^{*2}} \sin \tilde{\theta} + \frac{v^* + a^* T_e}{\omega^*} \cos \tilde{\theta} - \frac{v^*}{\omega^*} \right) \cos \tilde{\theta} \\ v_{x,k+1} &= (v_{x,k} + a_{x,k} T_e) \cos \tilde{\theta} + (v_{y,k} + a_{y,k} T_e) \sin \tilde{\theta} - \sqrt{\tilde{v}_x^2 + \tilde{v}_y^2} \\ v_{y,k+1} &= - (v_{x,k} + a_{x,k} T_e) \sin \tilde{\theta} + (v_{y,k} + a_{y,k} T_e) \cos \tilde{\theta} \\ a_{x,k+1} &= a_{x,k} \cos \tilde{\theta} + a_{y,k} \sin \tilde{\theta} - \sqrt{\tilde{a}_x^2 + \tilde{a}_y^2} \\ a_{y,k+1} &= -a_{x,k} \sin \tilde{\theta} + a_{y,k} \cos \tilde{\theta} \end{cases}$$

$$X_{k+1} = \begin{cases} x_{k+1} &= \left(x_k + v_{x,k}T_e + \frac{1}{2}a_{x,k}T_e^2\right) \cos \tilde{\theta} + \left(y_k + v_{y,k}T_e + \frac{1}{2}a_{y,k}T_e^2\right) \sin \tilde{\theta} - \frac{a^*}{\omega^*} \\ y_{k+1} &= -\left(x_k + v_{x,k}T_e + \frac{1}{2}a_{x,k}T_e^2\right) \sin \tilde{\theta} + \left(y_k + v_{y,k}T_e + \frac{1}{2}a_{y,k}T_e^2\right) \cos \tilde{\theta} + \frac{v^* + a^*T_e}{\omega^*} \\ v_{x,k+1} &= (v_{x,k} + a_{x,k}T_e) \cos \tilde{\theta} + (v_{y,k} + a_{y,k}T_e) \sin \tilde{\theta} - \sqrt{\tilde{v}_x^2 + \tilde{v}_y^2} \\ v_{y,k+1} &= -(v_{x,k} + a_{x,k}T_e) \sin \tilde{\theta} + (v_{y,k} + a_{y,k}T_e) \cos \tilde{\theta} \\ a_{x,k+1} &= a_{x,k} \cos \tilde{\theta} + a_{y,k} \sin \tilde{\theta} - \sqrt{\tilde{a}_x^2 + \tilde{a}_y^2} \\ a_{y,k+1} &= -a_{x,k} \sin \tilde{\theta} + a_{y,k} \cos \tilde{\theta} \end{cases} \quad (6.32)$$

avec

$$\begin{cases} \tilde{\theta} &= \omega^*T_e \\ \tilde{v}_x &= (v^* + a^*T_e) \cos(\omega^*T_e) - v^* \\ \tilde{v}_y &= (v^* + a^*T_e) \sin(\omega^*T_e) \\ \tilde{a}_x &= -(v^* + a^*T_e) \omega^* \sin(\omega^*T_e) + a^* \cos(\omega^*T_e) - a^* \\ \tilde{a}_y &= (v^* + a^*T_e) \omega^* \cos(\omega^*T_e) + a^* \sin(\omega^*T_e) - v^* \omega^* \end{cases}$$

Si l'égo-véhicule a un mouvement linéaire, on utilise les paramètres relatifs suivants (équation 6.30)

$$\begin{cases} \tilde{x} &= v^*T_e + \frac{1}{2} \cdot a^*T_e^2 \\ \tilde{y} &= 0 \\ \tilde{\theta} &= 0 \\ \tilde{v} &= a^*T_e \\ \tilde{a}_T &= 0 \\ \tilde{\omega} &= 0 \end{cases}$$

Le modèle cinématique dans le repère égo-centré dans ce cas donne

$$X_{k+1} = \begin{cases} x_{k+1} &= x_k + (v_{x,k} - v^*)T_e + \frac{1}{2}(a_{x,k} - a^*)T_e^2 \\ y_{k+1} &= y_k + v_{y,k}T_e + \frac{1}{2}a_{y,k}T_e^2 \\ v_{x,k+1} &= v_{x,k} + a_{x,k}T_e - a^*T_e \\ v_{y,k+1} &= v_{y,k} + a_{y,k}T_e \\ a_{x,k+1} &= a_{x,k} \\ a_{y,k+1} &= a_{y,k} \end{cases} \quad (6.33)$$

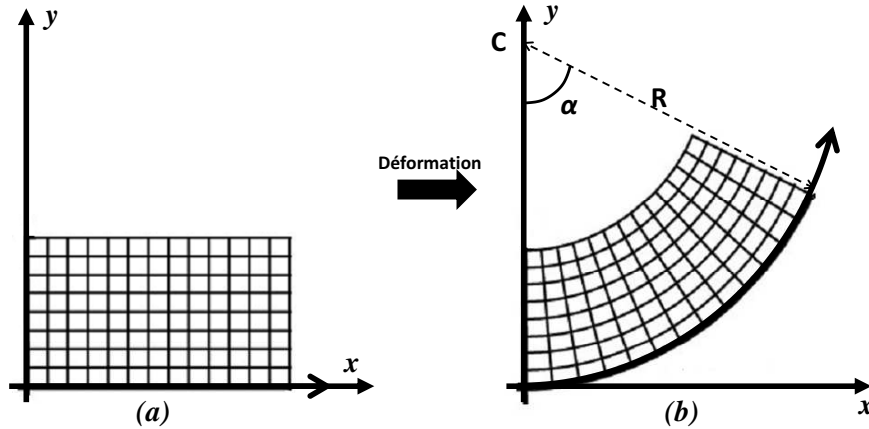


Figure 6.3: Déformation d'un quadrillage orthonormal (a) pour obtenir un quadrillage curviligne (b).

6.5 Déformation d'une trajectoire

Considérons une trajectoire quelconque tracée sur une route rectiligne. L'objectif de l'opération est de déterminer la trajectoire correspondant à la même manœuvre sur une route courbe. Pour illustrer la transformation, on peut considérer qu'il s'agit de déformer le quadrillage orthonormal de la figure 6.3.a pour obtenir le quadrillage curviligne de la figure 6.3.b. Le rayon de courbure est supposé constant dans le cas curviligne, c'est-à-dire que la route est parfaitement circulaire. Nous considérons le repère local (Ox, Oy) tel que l'axe des abscisses correspond à la ligne inférieure de la route rectiligne. Connaissant les coordonnées d'un point $P_r(x_r, y_r)$ de la trajectoire sur route rectiligne nous cherchons son équivalent $P_c(x_c, y_c)$ sur la route curviligne, afin de pouvoir construire point par point le résultat final.

Soit \mathcal{C} le cercle coïncidant avec la ligne extérieure de la route curviligne et soit r son rayon (rayon de courbure de la route). Soit maintenant $M_r(x_r, 0)$ le point de même abscisse que P_r et d'ordonnée nulle. Sa transformée M_c appartient au cercle \mathcal{C} et a pour coordonnée $M_c(r \sin \alpha, r - r \cos \alpha)$. L'angle α est obtenu à partir de la longueur de l'arc $\widehat{OM_c}$ qui n'est autre que x_r :

$$x_r = r \cdot \alpha \Rightarrow \alpha = \frac{x_r}{r}$$

Le vecteur unitaire \vec{u} de la figure 6.3.b a pour coordonnées $\vec{u}(-\sin \alpha, \cos \alpha)$. Le point P_c est obtenu par translation de vecteur $(y_r \vec{u})$ du point M_c . La transformation permettant d'obtenir le point P_c à partir du point P_r et du rayon de courbure r est finalement décrite par :

$$\begin{cases} x_c &= (r - y_r) \sin\left(\frac{x_r}{r}\right) \\ y_c &= r - (r - y_r) \cos\left(\frac{x_r}{r}\right) \end{cases}$$

Bibliographie

- [Sit, 2008] (2008). *Situations accidentelles*. CEESAR and LAB.
- [Mer, 2012a] (2012a). <http://www.auto-innovations.com/actualite/2108.html>.
- [Mer, 2012b] (2012b). www.autocar.co.uk/car-news/new-cars/new-mercedes-s-class-feast-sensors.
- [Aeberhard et al., 2011] Aeberhard, M., Paul, S., Kaempchen, N., and Bertram, T. (2011). Object existence probability fusion using dempster-shafer theory in a high-level sensor data fusion architecture. *IEEE Intelligent Vehicles Symposium (IV), Baden-Baden, Germany*.
- [Aziz et al., 1999] Aziz, A., Tummala, M., and Cristi, R. (1999). Fuzzy logic data correlation approach in multisensor multitarget tracking systems. *Journal of Signal Processing*, 76 :195–209.
- [Aziz, 2006] Aziz, A. M. (2006). Fuzzy track-to-track association and track fusion approach in distributed multisensor multitarget multiple-attribute environment. *Electrical Engineering Department, Military Technical College, Koubry Elkobba, Cairo, Egypt*.
- [Bar-Shalom, 1981] Bar-Shalom, Y. (1981). On the track-to-track correlation problem. *IEEE Transactions on Automatic Control*, 26 :571 – 572.
- [Bar-Shalom and Li, 1995] Bar-Shalom, Y. and Li, X. R. (1995). Multitarget multisensor tracking : principles and techniques. *Storrs, CT : YBS Publishing*, Chap 8.
- [Bar-Shalom and Scheffe, 1980] Bar-Shalom, Y. and Scheffe, M. (1980). Multitarget tracking using joint probabilistic data association. *19th IEEE Conference on Decision and Control, Symposium on Adaptive Processes*, 19 :807–812.
- [Bentley and Ottmann, 1979] Bentley, J. L. and Ottmann, T. A. (1979). Algorithms for reporting and counting geometric intersections. *IEEE Transactions on Computers*, C-28 (9) :643 – 647.
- [Berthelot et al., 2011] Berthelot, A., Tamke, A., Dang, T., and Breuel, G. (2011). Handling uncertainties in criticality assessment. *IEEE Intelligent Vehicles Symposium (IV), Baden-Baden, Germany*.
- [Bezdek et al., 1984] Bezdek, J. C., Ehrlich, R., and Full, W. (1984). The fuzzy c-means clustering algorithm. *Computers & Geosciences*, 10 :191–203.
- [Blackman and Popoli., 1999a] Blackman, S. S. and Popoli., R. (1999a). *Design and analysis of modern tracking systems*. ArtechHouse, Incorporated.

- [Blackman and Popoli., 1999b] Blackman, S. S. and Popoli., R. (1999b). *Design and analysis of modern tracking systems, Chapter 10 Multiple Sensor Tracking : System Implementation and Applications*. ArtechHouse, Incorporated.
- [Blackman and Popoli., 1999c] Blackman, S. S. and Popoli., R. (1999c). *Design and analysis of modern tracking systems, Chapter 9 Multiple Sensor Tracking : Issues and Methods*. ArtechHouse, Incorporated.
- [Breton, 2006] Breton, J.-C. (2006). Processus gaussiens. Master's thesis, Université de La Rochelle.
- [Caspi and Irani, 2002] Caspi, Y. and Irani, M. (2002). Aligning non-overlapping sequences. *International Journal of Computer Vision*, 48(1) :39–51.
- [Chang et al., 1996] Chang, K., Saha, R. K., Bar-Shalom, Y., and Alford, M. (1996). Performance evaluation of multisensor track-to-track fusion. *Proceedings of the 1996 IEEE/SICE/RSJ International Conference on Multisensor Fusion and Integration for Intelligent Systems*, pages 627 – 632.
- [Chen et al., 2002] Chen, L., Arambel, P., and Mehra, R. (2002). Estimation under unknown correlation : Covariance intersection revisited. *IEEE Transactions on Automatic Control*, 47 (11).
- [Coelingh et al., 2010] Coelingh, E., Eidehall, A., and Bengtsson, M. (2010). Collision warning with full auto brake and pedestrian detection. *IEEE Conference on Intelligent Transportation Systems, Madeira Island, Portugal*.
- [Daniel, 2010] Daniel, J. (2010). *Trajectory Generation and Data Fusion for Control-oriented Advanced Driver Assistance Systems*. PhD thesis, Université de Haute Alsace.
- [Dempster, 1968] Dempster, A. (1968). A generalization of bayesian inference. *Journal of Royal Statistical Society*, B 30 :205–247.
- [Durrant-Whyte, 2006] Durrant-Whyte, H. (2006). Multi-sensor data fusion. Technical report, Australian Centre for Field Robotics, The University of Sydney NSW 2006, Australia.
- [El-Zoghby et al., 2013] El-Zoghby, N., Cherfaoui, V., and Denoeux, T. (2013). Optimal object association from pairwise evidential mass functions. *Proceedings of the 16th Int. Conf. on Information Fusion (FUSION 13), Istanbul, Turkey*.
- [Elslande, 2006] Elslande, P. V. (2006). Erreur humaine et sûreté de fonctionnement des transports : l'exemple de la route. *INRETS, Département Mécanisme d'accidents, Paris*.
- [Fayad, 2009] Fayad, F. (2009). *Gestion de la confiance dans un système de fusion multisensorielle*. PhD thesis, University of Technology of Compiègne.
- [Fiorini and Shiller, 1998] Fiorini, P. and Shiller, Z. (1998). Motion planning in dynamic environments using velocity obstacles. *International Journal of Robotics Research*, 17 :760–772.

- [Fraichard and Asama, 2003] Fraichard, T. and Asama, H. (2003). Inevitable collision states. a step towards safer robots? *IEEE/RJS International Conference on Intelligent Robots and Systems, Las Vegas, Nevada*.
- [Fraichard and Howard,] Fraichard, T. and Howard, T. *Iterative Motion Planning and Safety, Chap 55 of Handbook of Intelligent Vehicle*. Springer.
- [Golias et al., 2002] Golias, J., Yannis, G., and Antoniou, C. (2002). Classification of driver-assistance systems according to their impact on road safety and traffic efficiency. *Transport Reviews Journal*, 22 :179–196.
- [Gooding et al., 2005] Gooding, M. J., Kennedy, S. H., and Noble, J. A. (2005). Temporal calibration of freehand three-dimensional ultrasound using image alignment. *Ultrasound in Medicine & Biology*, 31.
- [Haimovich et al., 1993] Haimovich, A. M., Yosko, J., Greenberg, R., Parisi, M., and Becker, D. (1993). Fusion of sensors with dissimilar measurement/tracking accuracies. *IEEE Trans. Aerospace Electronic Systems*, 29 :245 – 250.
- [Hayya et al., 1975] Hayya, J., Armstrong, D., and Gressis, N. (1975). A note on the ratio of two normally distributed variables. *Management Science*.
- [Hillenbrand et al., 2006] Hillenbrand, J., Spieker, M., and Kroschel, K. (2006). A multilevel collision mitigation approach-its situation assessment, decision making and performance tradeoffs. *IEEE Transactions on intelligent transportation systems*.
- [Hülhnagen et al., 2010] Hülhnagen, T., Dengler, I., Tamke, A., Dang, T., and Breuel, G. (2010). Maneuver recognition using probabilistic finite-state machines and fuzzy logic. *IEEE Intelligent Vehicles Symposium, San Diego, CA, USA*.
- [Houenou et al., 2012] Houenou, A., Bonnifait, P., Cherfaoui, V., and Boissou, J.-F. (2012). A track-to-track association method for automotive perception systems. *IEEE Intelligent Vehicles Symposium, Alcalá de Henares, Spain*.
- [Huber et al., 2009] Huber, M., Schlegel, M., and Klinker, G. (2009). Temporal calibration in multisensor tracking setups. *8th IEEE International Symposium on Miwed and Augmented Reality, Orlando, FL*.
- [Hundelshausen et al., 2008] Hundelshausen, F. V., Himmelsbach, M., Hecker, F., Mueller, A., and Wuensche, H.-J. (2008). Driving with tentacles-integral structures forsensing and motion. *Journal of Field Robotics*, 25(9) :640 – 673.
- [Kaempchen and Dietmayer, 2003] Kaempchen, N. and Dietmayer, K. (2003). Data synchronization strategies for multi-sensor fusion. *10th World Congress on Intelligent Transport Systems, Madrid, Spain*.
- [Keller et al., 2011] Keller, C., Dang, T., Fritz, H., Joos, A., Rabe, C., and Gavrilu, D. M. (2011). Active pedestrian safety by automatic braking and evasive steering. *IEEE Transactions on Intelligent Transportation Systems*.
- [Köhler et al., 2013] Köhler, S., Schreiner, B., Ronalter, S., Doll, K., Brunsmann, U., and Zindler, K. (2013). Autonomous evasive maneuvers triggered by

- infrastructure-based detection of pedestrian intentions. *IEEE Intelligent Vehicles Symposium, Gold Coast, Australia.*
- [Kluge, 1994] Kluge, K. (1994). Extracting road curvature and orientation from image edge points without perceptual grouping into features. *IEEE Intelligent Vehicles Symposium, Paris, France.*
- [Kluge and Thorpe, 1992] Kluge, K. and Thorpe, C. (1992). Representation and recovery of road geometry in yarf. *IEEE Intelligent Vehicles Symposium, Detroit, USA*, pages 114–119.
- [Konstantinova et al., 2003] Konstantinova, P., Udvarrev, A., and Semerdjiev, T. (2003). A study of target tracking algorithm using global nearest neighbor approach. *International conference on computer systems and technologies - CompSys Tech’.*
- [Lambert et al., 2008] Lambert, A., Gruyer, D., and Pierre, G. S. (2008). A fast monte carlo algorithm for collision probability estimation. *International Conference on Control, Automation, Robotics and Vision, Hanoi, Vietnam.*
- [Large et al., 2004] Large, F., Vasquez, D., Fraichard, T., and Laugier, C. (2004). Avoiding cars and pedestrians using velocity obstacles and motion prediction. *IEEE Intelligent Vehicles Symposium, Parma, Italy.*
- [Laugier et al., 2011] Laugier, C., Paromtchik, I. E., Perrollaz, M., Yoder, J.-D., Tay, C., Yong, M., Nègre, A., and Mekhnacha, K. (2011). Probabilistic analysis of dynamic scenes and collision risks assessment to improve driving safety. *IEEE Intelligent Transportation Systems Magazine*, 3 :4 – 19.
- [Li and Nashashibi, 2012] Li, H. and Nashashibi, F. (2012). Cooperative multi-vehicle localization using split covariance intersection filter. *IEEE Intelligent Vehicles Symposium, Alcalá de Henares, Spain.*
- [Liggins et al., 2008a] Liggins, M. E., Hall, D. L., and Llinas, J. (2008a). *Handbook of Multisensor Data Fusion. Theory and Practice.* CRC Press.
- [Liggins et al., 2008b] Liggins, M. E., Hall, D. L., and Llinas, J. (2008b). *Handbook of Multisensor Data Fusion. Theory and Practice, Chapter 17 Distributed fusion architectures, algorithms and performance.* CRC Press.
- [Lim et al., 2011] Lim, Y.-C., Lee, C.-H., Kwon, S., and Kim, J. (2011). Event-driven track management method for robust multi-vehicle tracking. *IEEE Intelligent Vehicles Symposium (IV), Baden-Baden, Germany.*
- [Louwerse and Hoogendoorn, 2004] Louwerse, W. and Hoogendoorn, S. (2004). Adas safety impacts on rural and urban highways. *IEEE Intelligent Vehicles Symposium Parma.*
- [Lundgren and Tapani, 2006] Lundgren, J. and Tapani, A. (2006). Evaluation of safety effects of driver assistance systems through traffic simulation. *Transportation Research Record, Washington D.C.*, pages 81–88.

- [Martinez et al., 2008] Martinez, A. M., Carter, E., Naing, C., Simon, M., and Hermitte, T. (2008). Accident causation and pre-accidental driving situations. Technical report, Traffic Accident Causation in Europe (TRACE) & Information Society Technologies, Deliverable D 2.1.
- [Martinez-Gomez and Fraichard, 2008] Martinez-Gomez, L. and Fraichard, T. (2008). An efficient and generic 2d inevitable collision state-checker. *IEEE/RSJ International Conference on Intelligent Robots and Systems*.
- [Mercier et al., 2011] Mercier, D., Lefèvre, E., and Jolly, D. (2011). Object association with belief functions, an application with vehicles. *Information Sciences*, 181 :5485–5500.
- [Morris et al., 2011] Morris, B., Doshi, A., and Trivedi, M. (2011). Lane change intent prediction for driver assistance : On-road design and evaluation. *IEEE Intelligent Vehicles Symposium Baden-Baden, Germany*, pages 5 – 9.
- [Oliver and Pentland, 2000] Oliver, N. and Pentland, A. P. (2000). Graphical models for driver behavior recognition in a smartcar. *IEEE Intelligent Vehicles Symposium, Gearborn (MI), USA*.
- [Polychronopoulos et al., 2004] Polychronopoulos, A., Tsogas, M., Scheunert, U., Andreone, L., and Tango, F. (2004). Dynaminc situation and threat assessment for collision warning systems : the euclide approach. *IEEE Intelligent Vehicles Symposium Parma, Italy*.
- [Qi et al., 2013] Qi, W.-J., Zhang, P., and Deng, Z.-L. (2013). Covariance intersection fusion kalman estimators for multi-sensor system with colored measurement noises. *Reasearch Journal of Applied Sciences, Engineering and Technology*, 6(10) :1872–1878.
- [Quan and Mohr, 1989] Quan, L. and Mohr, R. (1989). Determining perspective structures using hierarchical hough transform. *Journal of Pattern Recognition Letters*, 9 :279–286.
- [Rieger et al., 2005] Rieger, G., Scheef, J., Becker, H., Stanzel, M., and Zobel, R. (2005). Active safety systems change accident environment of vehicles significantly - a challenge for vehicle design. *International Technical Conference on the Enhanced Safety of Vehicles (ESV), Washington DC*.
- [Saha, 1994] Saha, R. K. (1994). Effect of cross-correlation on track-to-track fusion. *Proc. SPIE 2235*, pages 474 – 485.
- [Saha, 1996] Saha, R. K. (1996). Track-to-track fusion with dissimilar sensors. *IEEE Trans. Aerospace Electronic Systems*, 32 :1021 – 1029.
- [Schubert et al., 2008] Schubert, R., Richter, E., and Wanielik, G. (2008). Comparison and evaluation of advanced motion models for vehicle tracking. *International Conference on Information Fusion, Cologne, Germany*.
- [Shafer, 1976] Shafer, G. (1976). A mathematical theory of evidence. *Princeton University Press, Princeton, N.J.*

- [Silberg and Wallace, 2012] Silberg, G. and Wallace, R. (2012). Self-driving cars : The next revolution. White paper, KPMG LLP & Center of Automotive Research.
- [Sittler, 1964] Sittler, R. W. (1964). An optimal data association problem in surveillance theory. *IEEE Trans. on Military Electronics*, IT-20 :423–432.
- [Takashi et al., 1989] Takashi, A., Hongo, T., Ninomiya, Y., and Sugimoto, G. (1989). Local path planning and motion control for agv in positioning. *IEEE/RSJ International Workshop on Intelligent Robots and Systems*, pages 392 – 397.
- [Tamke et al., 2011] Tamke, A., Dang, T., and Breuel, G. (2011). A flexible method for criticality assessment in driver assistance systems. *IEEE Intelligent Vehicles Symposium Baden-Baden, Germany*.
- [Tessier, 2007] Tessier, C. (2007). Systeme de localisation base sur une strategie de perception cognitive applique a la navigation autonome d’un robot mobile. Master’s thesis, Universite Blaise Pascal - Clermont II.
- [Tseng et al., 2005] Tseng, C.-C., Cheng, H.-Y., and Jeng, B.-S. (2005). A lane detection algorithm using geometry information and modified hough transform. *18th IPPR Conference on Computer Vision, Graphics and Image Processing, Taipei, Taiwan*.
- [unece, 2008] unece (2008). <http://www.unece.org/trans/main/wp29/wp29regs1-20.html>. *Commission Economique des Nations Unies pour l’Europe*.
- [Werling et al., 2010] Werling, M., Ziegler, J., Kammel, S., and Thrun, S. (2010). Optimal trajectory generation for dynamic street scenario in a frenet frame. *IEEE International Conference on Robotics and Automation, Anchorage, Alaska, USA*.
- [Willner et al., 1976] Willner, D., Chang, B., and Dunn, K. P. (1976). Kalman filter algorithms for a multi-sensor system. *Proceedings of IEEE Conference on Decision and Control*, pages 570 – 574.
- [Yao et al., 2012] Yao, W., Zhao, H., Davoine, F., and Zha, H. (2012). Learning lane change trajectories from on-road driving data. *IEEE Intelligent Vehicles Symposium, Alcalá de Henares, Spain*.

Liste des symboles

ACC	Adaptive Cruise Control
ADAS	Advanced Driver Assistant System
AEBS	Advanced Emergency Braking System
APV	Algorithme de Prédiction de Voie
CAN	Controller Area Network
CAS	Collision Avoidance System
DARPA	Defense Advanced Research Projects Agency (USA)
ESP	Electronic Stability Program
FCM	Fuzzy C-Mean clustering, [en français]
GNN	Global Nearest Neighbor algorithm, Algorithme du plus proche voisin généralisé.
GPS	Global Positioning System
ICS	Inevitable CollisionState
JPDA	Joint Probabilistic Data Association, Association probabiliste jointe de données
LKA	Lane Keeping Assist
MAS	Module d'Analyse de Scène
MD	Module de Décision
MRM	Module/Méthode de Reconnaissance de Manœuvre
PGC	Processus de Gestion du Capteur
SP	Système de Perception
UNECE	United Nations Economic Commission for Europe
VO	Velocity Obstacle

