

Table des matières

Introduction générale	1
Chapitre I Positionnement des problèmes	5
I.1 Application Transport.....	5
I.2 Problématique scientifique étudiée.....	11
I.3 Méthode d'estimation	12
I.3.1 Estimation dynamique de processus markoviens	12
I.3.2 Filtrage linéaire optimal : le filtre de Kalman.....	14
I.3.3 Filtrage non-linéaire.....	15
I.3.3.1 Le filtre de Kalman étendu	16
I.3.3.2 Le filtre de Kalman « Unscented ».....	17
I.3.3.3 Méthodes de Monte-Carlo séquentielles : l'approche particulaire	18
I.4 Association Temporelle de données	23
I.4.1 Introduction	23
I.4.2 Méthodes d'association de données mono-objet	25
I.4.2.1 Méthode du plus proche voisin (NN)	25
I.4.2.2 Méthode d'association probabiliste de données (PDA).....	26
I.4.3 Méthode d'association de données multi-objets.....	30
I.4.3.1 Méthode des hypothèses multiples (MHT).....	30
I.4.3.2 Méthode d'association probabiliste conjointe de données (JPDA)	31
I.5 Capteurs actifs	36
I.5.1 Introduction	36
I.5.2 La technologie laser.....	36
I.5.2.1 Domaines d'utilisation du laser	36
I.5.2.2 Principe des télémètres lasers utilisés pour la surveillance et l'automobile	37

I.5.3 Evolution des capteurs laser automobile de détection d'obstacle.....	38
I.5.4 Présentations des capteurs Sick et IBEO utilisés et de leurs données	42
I.5.4.1 Le capteur laser automobile IBEO LD	42
I.5.4.2 Les capteurs de surveillance Sick LMS 200.....	44
Chapitre II Suivi multi-objets avec intégration du contexte capteur/objet	49
II.1 Détection des objets	50
II.1.1 Introduction	50
II.1.2 Méthodes supervisées.....	51
II.1.2.1 Exemple de méthodes supervisées	51
II.1.2.2 <i>K</i> -means (<i>K</i> -moyennes).....	53
II.1.3 Méthodes non supervisées.....	54
II.1.3.1 Méthodes de classification non supervisées rencontrées dans la littérature	54
II.1.3.2 Détection par classification hiérarchique ascendante.....	56
II.1.3.3 Détection séquentielle (issue de l'algorithme des nuées dynamiques).....	58
II.1.3.4 Comparaison des méthodes de détection présentées	60
II.1.4 Détection des objets dans des données réelles	62
II.2 Suivi d'objets en mouvement.....	64
II.2.1 Filtrage	65
II.2.1.1 Modèles de mouvement.....	65
II.3 Association probabiliste de données	67
II.3.1 Association temporelle	67
II.3.1.1 Critère d'association	67
II.3.2 Gestion des pistes	68
II.3.3 L'approche PDAF (Probabilistic Data Association Filter)	70
II.4 Intégration du contexte.....	71
II.4.1 Position du problème.....	71
II.4.2 Apport des réseaux bayésiens à l'association de données.....	72
II.4.2.1 Rappels sur les réseaux bayésiens	72

II.4.2.2 Détermination de la probabilité de détection par réseau bayésien	74
II.5 Expérimentations.....	75
II.5.1 Données synthétiques	75
II.5.1.1 Radar à balayage	75
II.5.1.2 Résultats de détection et estimation	76
II.5.2 Résultats sur données réelles (capteur IBEO)	81
II.5.3 Résultats sur données réelles (capteur SICK LMS)	83
II.6 Conclusion.....	86
Chapitre III Détection à partir de données télémétriques	87
III.1 Position générale du problème de détection	87
III.2 Performances des systèmes de détection	89
III.2.1 La détection à partir de données de type radar.....	90
III.2.2 La détection pour un télémètre laser à balayage	93
III.3 Les données télémétriques	94
III.3.1 Expression des mesures	94
III.3.2 Imprécisions et incertitudes sur les mesures	95
III.4 Le clustering.....	96
III.4.1 <i>Clustering</i> adaptatif.....	98
III.5 La segmentation	100
III.5.1 Détermination par minimisation quadratique.....	101
III.5.1.1 Extraction de droites en coordonnées cartésiennes	101
III.5.1.2 Extraction de droites en coordonnées polaires.....	102
III.5.2 Quelques algorithmes de segmentation.....	104
III.5.2.1 Algorithme Incrémental (ou <i>Line Tracking</i>)	104
III.5.2.2 Algorithmes de type <i>Split and Merge</i>	105
III.5.2.3 Quelques autres algorithmes non implémentés	107
III.5.3 Détermination des autres paramètres du segment	110
III.5.3.1 Calcul des extrémités du segment.....	110

III.5.3.2 Calcul de la longueur du segment	111
III.5.3.3 Calcul du milieu du segment.....	111
III.5.4 Modélisation par des primitives de type rectangle.....	112
III.5.4.1 Détection des coins	113
III.5.4.2 Modélisation par un rectangle.....	114
III.6 Une nouvelle méthode de segmentation	115
III.6.1 Mise en évidence d'un invariant	116
III.6.2 Principe de la méthode de segmentation.....	117
III.6.2.1 Segmentation par recherche d'invariants	117
III.6.2.2 Extraction des paramètres des segments	123
III.6.3 Application de la méthode sur données bruitées.....	125
III.7 Evaluation de l'algorithme de détection par invariant	128
III.7.1 Présentation du protocole d'expérimentation.....	129
III.7.2 Evaluation et comparaison des méthodes de détection.....	132
III.7.2.1 Comparaison avec les autres algorithmes de détection.....	132
III.7.2.2 Performances de l'algorithme <i>Inv</i> en fonction du contexte capteur-objet.....	138
III.7.2.3 Performances de l'algorithme <i>Inv</i> en fonction du contexte objet/objet.....	141
III.7.3 Résultats sur données réelles.....	142
III.8 Conclusion	144
Chapitre IV Suivi multi-objets avec intégration du contexte (capteur/objet, objet/objet)....	147
IV.1 Intégration du contexte	148
IV.1.1 Visibilité (dépendance capteur /objet)	148
IV.1.2 Occultation (dépendance objet/objet)	149
IV.1.3 Détectabilité	152
IV.1.4 Estimation de la probabilité de détection.....	154
IV.2 Application des réseaux bayésiens à l'estimation et du suivi par une approche JPDA	156
IV.3 Résultats expérimentaux	162
IV.3.1 Protocole de l'étude	162

IV.3.2 Evaluation de l'apport du contexte	163
IV.4 Conclusion	171
Conclusion et perspectives.....	173
Annexe A : Présentation des réseaux bayésiens	175
Annexe B : Détermination statistique de l'invariant pour la détection	186
Bibliographie.....	189

Introduction générale

Ce manuscrit présente les travaux que j'ai réalisés au sein des laboratoires LEOST de l'INRETS à Villeneuve d'Ascq et LASL de l'Université de Littoral Côte d'Opale. Ces travaux se placent dans le cadre général de l'assistance au conducteur et plus particulièrement de la sécurité. L'objectif est ici de surveiller à chaque instant l'environnement du véhicule et d'informer le conducteur de situations potentiellement dangereuses. Ce dispositif permet alors d'envisager une manœuvre d'évitement (« collision avoidance ») ou d'atténuation de collision (« collision mitigation »).

Dans le domaine du transport routier, plusieurs solutions ont été envisagées. Elles reposent sur l'utilisation de différents capteurs : caméra, sonar, radar, lidar qui permettent d'évaluer la distance de chaque objet (véhicule, piéton, etc..) présent dans la scène. De nombreux projets à l'échelle nationale ou internationale ont eu notamment pour tâche de développer des systèmes capables de remplir cet objectif. Ces travaux ont été menés dans le cadre du projet Ravioli (Radar et Vision Orientable, Lidar) regroupant des partenaires de l'Université des Sciences et Technologies de Lille, l'Université de Valenciennes et du Hainaut Cambrésis, l'Université d'Artois, l'Université du Littoral Côte d'Opale et l'INRETS de Villeneuve d'Ascq. Ce projet fédérateur a eu pour objectif de concevoir un système multicapteurs de détection et suivi d'objets en regroupant les compétences de chaque acteur.

Concernant cette thèse, nous nous sommes focalisés sur l'étude du problème de détection et suivi multi-objets à partir de données télémétriques. Sur une première partie, nous nous sommes intéressés à l'exploitation de données radar synthétiques afin d'assurer la jonction avec l'équipe chargée de développer le radar au sein du projet Ravioli. Dans une deuxième partie, nous avons développé des méthodes permettant d'effectuer une détection et un suivi multi-objets dans le cas de données télémétriques lidar dont le comportement présente de fortes similitudes avec l'aspect radar.

A l'étude du problème, deux points particuliers ont retenu notre attention. En considérant l'ensemble de la chaîne de traitement, la détection occupe une place privilégiée car elle conditionne directement les performances globales de la méthode. Le deuxième point concerne le processus d'association-suivi qui doit permettre d'associer efficacement les mesures disponibles à chaque instant avec l'objet dont on est en train d'estimer les paramètres.

L'approche retenue pour l'étape d'association repose sur les méthodes d'association probabiliste de données (Probabilistic Data Association, Joint Probabilistic Data Association). Contrairement aux méthodes MHT (Multi Hypothesis Tracking) qui envisagent l'ensemble des associations possibles en se heurtant à une combinatoire explosive, les méthodes PDA/JPDA se limitent à n'envisager que les mesures les plus probables pour l'association. Ces méthodes permettent également de considérer le fait qu'une mesure disponible puisse ne pas être liée à un objet. Elles exploitent donc directement les notions de probabilité de détection (probabilité de détecter la cible) et de probabilité de fausses alertes (probabilité que la cible détectée n'en soit en fait pas une). Ces notions, chères aux radaristes, constituent le socle des méthodes d'association probabiliste de données car elles en conditionnent directement les performances.

Dans le cas usuel de cibles ponctuelles, comme c'est souvent le cas (supposé) en radar, le calcul de ces grandeurs peut se faire de manière analytique à partir de considérations statistiques sur la nature du bruit de mesure et des caractéristiques de la cible. Ce point n'est donc généralement pas une difficulté à la mise en œuvre des méthodes PDA pour ce contexte applicatif. A noter que la détermination de ces probabilités est bien évidemment directement liée au type de détecteur employé. Dans le cas qui nous concerne, on s'intéresse à la détection d'objets distribués à partir de données télémétriques lidar qui sont en général très focalisées.

Ces données nécessitent aussi de procéder à une étape de détection afin d'estimer le nombre d'objets présents dans la scène ainsi que leur distance au capteur. Il est clair que l'étape de détection ne peut se résumer ici à un simple seuillage, comme pratiqué avec succès dans le cas radar, mais nécessite de procéder à une agrégation des mesures liées au même objet. Le calcul des probabilités de détection et fausses alarmes indispensables à l'étape d'association, s'en trouve beaucoup plus complexe.

Concernant la probabilité de fausse alarme, il apparaît très difficile de pouvoir la déterminer de manière analytique car elle est directement et majoritairement liée au détecteur qui, dans le cas présent, ne peut se résumer à des opérations mathématiques élémentaires. Il convient donc, comme nous le ferons dans le chapitre III, d'estimer cette probabilité de manière expérimentale pour chaque détecteur employé.

La probabilité de détection demeure quant à elle, non seulement fortement liée au détecteur, mais également au contexte de la scène :

- le contexte capteur/objet : les caractéristiques respectives de l'objet (taille, distance, réflectivité...) et du capteur (ouverture angulaire, quantification, portée...) influent directement sur cette probabilité.
- le contexte objet/objet : les interactions entre les différents objets (proximité, occultation...) conditionnent également fortement la probabilité de détection de chaque objet.

Pour pouvoir intégrer ces informations globales de contexte, nous proposons une méthode d'association-suivi basée sur les réseaux bayésiens qui autorise l'intégration de paramètres liés aux caractéristiques des objets et du capteur. Cette approche est alors appliquée sur des données synthétiques et sur des situations réelles en zone urbaine.

En résumé, ce mémoire de thèse est structuré comme suit :

- Un premier chapitre brosse le contexte général applicatif de la thèse en introduisant l'ensemble des étapes de la chaîne de perception (capteur, détection, association, estimation) et les principales approches associées.
- Le deuxième chapitre propose une méthode de suivi multi-objets qui repose sur l'exploitation du contexte capteur/objet. On s'est notamment ici pleinement imprégné du projet Ravioli en respectant les contraintes temps-réel imposées par l'application. Nous avons donc exploité une méthode de détection relativement frustre qui délivre les positions des objets détectés. Le cadre de ce chapitre qui exploite uniquement le contexte capteur/objet permet d'envisager la mise en œuvre de la méthode PDA associée au filtrage de Kalman dans le processus d'association-estimation (l'hypothèse de séparabilité étant ici supposée respectée). On montre l'apport de notre approche sur données synthétiques radar [Wahl, 1997], sur données réelles décrivant un scénario urbain fourni par l'Université de

Technologie de Compiègne (délivrées par un capteur SICK LMS 200) et un scénario proche du contexte autoroutier fourni par l'Ecole Nationale Supérieure des Mines de Paris (délivrées par un capteur IBEO et obtenues grâce au logiciel d'acquisition multicapteurs RTMaps de la société INTEMPORA).

- Afin d'envisager le problème dans sa globalité, le chapitre III se propose de revenir sur la formulation du problème de détection tel qu'introduit par les radaristes [Skolnik, 1990]. Nous envisageons en particulier l'extension de ce problème au cas des données télémétriques et montrons l'impact sur les performances globales du détecteur. Dans la chaîne de traitement, la détection occupe une place centrale car elle conditionne les performances de l'ensemble. En effet, il est illusoire de mettre en œuvre des techniques optimales de filtrage, si l'étape de détection n'est pas performante. Nous proposons donc dans ce chapitre une nouvelle méthode de détection qui exploite les caractéristiques géométriques particulières liées au contexte applicatif.
- Le dernier chapitre propose enfin de traiter le problème de suivi multi-objets avec intégration du contexte capteur/objet mais également objet/objet. Cela oblige donc à exploiter l'ensemble des dépendances géométriques et statistiques que les objets entretiennent. Le nœud central de notre approche est donc la méthode Joint Probabilistic Data Association qui se prête particulièrement à des telles considérations. Nous présentons alors à partir du détecteur développé dans le chapitre III des résultats sur données réelles délivrées par IBEO et acquises par RTMaps.
- Nous concluons sur les résultats obtenus durant cette thèse et les perspectives que ces travaux ouvrent dans le domaine.

Chapitre I

Positionnement des problèmes

I.1 Application Transport

La lecture des statistiques d'accident du site de la prévention routière [LPR_URL] est terrible. La page « les grandes données de l'accidentologie » nous accueille froidement ainsi :

« Les données de l'accidentologie : sur l'ensemble de l'année 2007, le nombre de tués sur les routes recule de 1,9 %. Il s'agit de la sixième année consécutive de baisse, soit une diminution de l'ordre de 40 % du nombre de personnes tuées en cinq ans.

La baisse de la mortalité concerne surtout les conducteurs et les passagers des véhicules légers. Il n'y a pas d'amélioration pour les piétons, ni pour les usagers des deux-roues motorisés. Les nombres d'accidents corporels et de blessés sont quant à eux en légère augmentation :

- 4620 personnes ont trouvé la mort en 2007, à la suite d'un accident de la route en France (métropole), soit en moyenne 13 par jour. Par million d'habitants, la France compte encore 40 à 60 % de tués en plus que la Suède ou la Grande-Bretagne...
- 103 201 personnes ont été blessées en 2007 (soit 283 par jour en moyenne). On estime approximativement à 4 400 le nombre de blessés avec séquelles majeures : lésions avec perte de substance nerveuse (encéphale, moelle épinière, racines nerveuses) ou perte d'un membre ou destruction de grosses articulations (extrapolation d'une étude publiée dans le BEH, Bulletin épidémiologique hebdomadaire, n°19).

Cet aspect dangereux de la route est celui qui très tôt, à la fin des années 80, a conduit l'Europe, puis les Etats-Unis et le Japon dans les années 90, à proposer des programmes de recherche en vue d'améliorer la sécurité routière, de diminuer les risques tout en réfléchissant au problème de l'encombrement des routes, de la qualité de l'environnement et de leur impact sur l'économie des pays développés [Wahl, 1997]. Ces programmes sont vastes et variés avec des études aussi bien en vue d'obtenir des solutions technologiques que d'autres en vue d'approcher une meilleure connaissance des comportements humains des utilisateurs de la route. [INRETS, 2005] donne un bon aperçu, au travers de paroles de chercheurs de l'INRETS, de différents objets de recherche à l'Institut sur la sécurité de la route :

- responsabilité de l'homme : vitesse, alcool, drogues, fatigue, téléphone, véhicule mal entretenu ;
- vulnérabilité de l'homme : comportement inadapté par temps de brouillard peut-être due à une mauvaise perception du comportement des autres conducteurs ou à la réduction de la distance de visibilité et celle des contrastes, atténuation des capacités de traitement des

informations avec le vieillissement, influence des médicaments, vulnérabilité des motards, motocyclistes, des piétons –en particulier des enfants) ;

- rôle des infrastructures pouvant avoir un impact positif ou négatif quant à la gravité d'un accident,
- rôle du véhicule : des études sont réalisées sur la sécurité passive (son ergonomie, sa conception) pour limiter l'impact des accidents sur les passagers et sur la sécurité actif en vue d'éviter les accidents en apportant des aides à la conduite (déttection de piétons, limiteur de vitesse, modification de trajectoire du véhicule...).

C'est ainsi qu'en Europe, dès la fin des années 1980, le programme ATT (« *Advanced Telematics Transportation* ») a été établi pour aider à l'amélioration de la sécurité routière et diminuer l'encombrement du réseau routier européen. En 1989, le programme DRIVE I (« *Dedicated Road Infrastructure for Vehicle safety in Europe* ») incluait un large éventail de projets de recherche et de développement. Il a été suivi du programme DRIVE II et du programme PROMETHEUS (« *PROgram for an European Traffic system with Highest Efficiency and Unprecedented Safety* ») en 1993.

PROMETHEUS a été divisé en trois sous-programmes industriels et quatre de recherches fondamentales. Les sous-programmes industriels se sont intéressés aux systèmes de communication et d'information :

- PRO-CAR : recherches sur les systèmes autonomes pour l'information et l'assistance aux conducteurs,
- PRO-NET : recherches sur les systèmes de communication entre véhicules,
- PRO-ROAD : recherches sur les systèmes de communication entre véhicule et infrastructure.

Les sous-programmes de recherches fondamentales ont concerné :

- PRO-ART : l'étude de méthodes et systèmes utilisant l'intelligence artificielle,
- PRO-CHIP : l'étude et le développement d'équipements de traitement intelligent embarqués à bord du véhicule,
- PRO-COM : l'étude de méthodes et la proposition de standards pour les besoins de la communication,
- PRO-GEN : la simulation de scénarios de trafic pour l'introduction des nouveaux systèmes.

D'autre part, trois organisations européennes ont vu le jour en 1989 (FEHRL) et en 1991 (ERTICO et ACEA) :

- FEHRL (« *Forum of European National Highway Research Laboratories* ») est « une association internationale administrée par les directeurs de chacun des instituts nationaux. Elle offre une structure coordonnée pour les intérêts des 30 centres de recherches et techniques nationaux des états membres de l'union européenne, des pays de l'EFTA et du reste de l'Europe ». Le plan de développement 2003-2007 de l'association couvre les cinq thèmes suivants : l'environnement, l'énergie et les ressources, la mobilité, les transports et l'infrastructure, la conception et la production [FEH_URL].
- ERTICO (« *European Road Transport telematics Implementation Co-ordination Organisation* ») a un partenariat privé-public qui représente les intérêts des constructeurs, des opérateurs, des fournisseurs de services et des administrations publiques. C'est une

organisation à but non lucratif dont les objectifs sont de contribuer à la coordination des prochaines activités de la télématique dans les domaines du transport et du trafic européens. Cette organisation fournit aussi un support pour le transfert de ces activités du domaine de la recherche à celui de l'expérimentation vers des applications pratiques [ERT_URL]. Ils apportent actuellement leur soutien à des programmes promouvant les technologies ITS et leurs applications pour les thèmes de la sécurité de tous les usagers de la route, de la sûreté (usage de technologie ITS pour une mobilité plus sûre), l'augmentation de l'efficacité des réseaux de transports et l'amélioration de l'environnement, la coopération nationale et internationale.

- ACEA (« *European Automobile Manufacturers Association* ») représente les intérêts au niveau européen des 15 constructeurs de voitures, camions et de bus. « Cette association a été à l'origine créée en réponse aux rapports graduels de responsabilités gouvernementales vers Bruxelles sur bon nombre des aspects complexes économiques, sociaux, techniques et légaux relatifs à l'intégration européenne. Son origine résulte en grande partie du besoin de représenter les contributions technologiques, industrielles et commerciales et l'intérêts des compagnies membres » [ACE_URL].

Après PROMETHEUS, les projets européens concernant la sécurité routière ont repris de l'ampleur avec le 5^{ème} programme-cadre (1998-2002) de recherche et développement européen (PCRD), en particulier au travers du programme de recherche ADASE2 (« *Advanced Driver Assistance Systems in Europe* »). On retrouve au travers des projets de ce programme ADASE2 (figure 1, [AHS_URL]) et de son approche de la sécurité (figure 1, [AHS_URL]) les réflexions déjà présentes dans le programme PROMETHEUS, mais avec des réponses technologiques plus avancées.

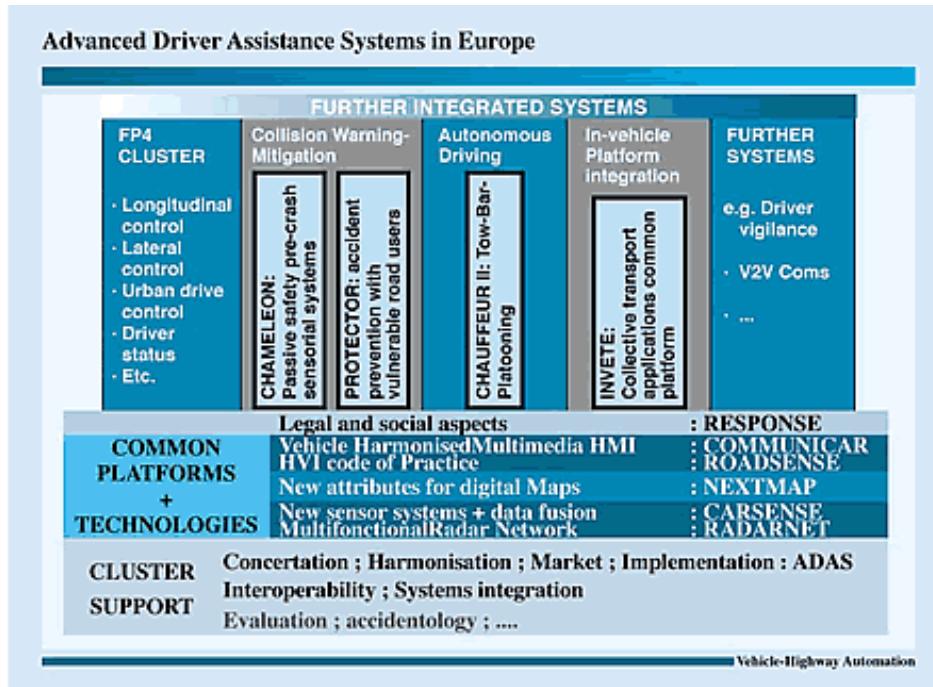


Figure 1 : Les projets du programme ADASE2 en 2001 (source : [AHS_URL]).

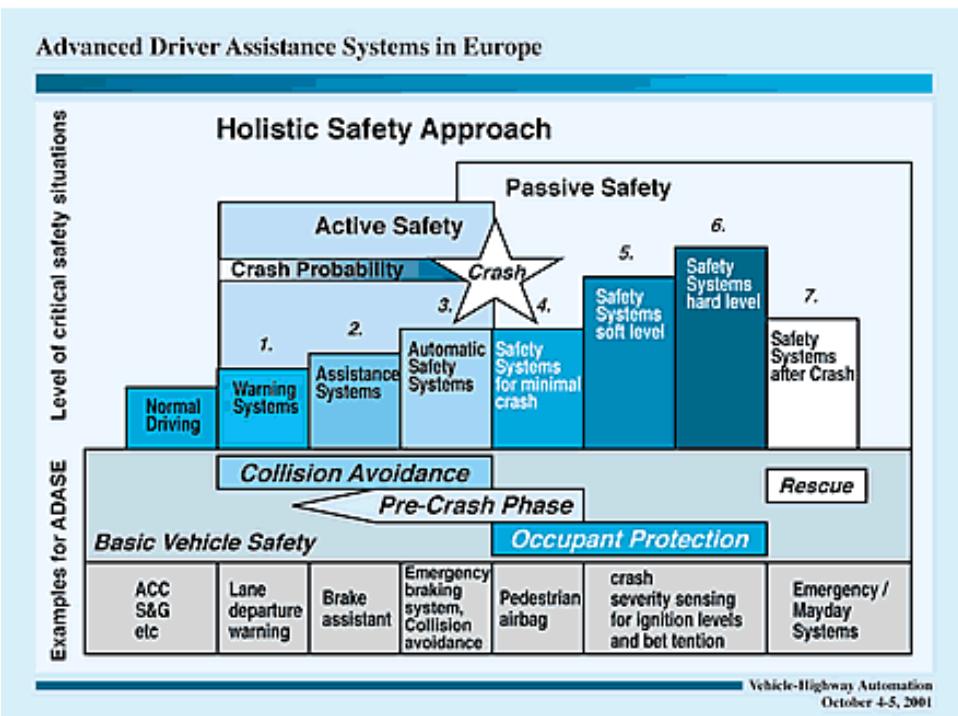


Figure 2 : L'approche de sécurité holistic du programme ADASE2 en 2001 (source : [AHS_URL]).

En 2002, « eSafety », initiative de l'« Intelligent Car Initiative » (i2010, [EIS_URL]), a été lancée dans le cadre d'un partenariat privé-public dans le but « d'améliorer la sécurité routière grâce aux technologies de l'information et des communications » [eSafety, 2008]. « eSafety » dispose d'un groupe directeur co-présidé par la commission européenne et les associations ERTICO et ACEA, d'un forum de 150 membres représentant les différentes parties intéressées dans le domaine de la sécurité routière et de quatorze groupes de travail présidés par des industriels discutant de questions stratégiques ou technologiques. Cette initiative, toujours très active, vise à « accélérer le développement, le déploiement et l'utilisation de systèmes de sécurité de véhicules par des activités de coordination, d'information du public et de recherche ». Elle s'intéresse plus particulièrement aux dispositifs autonomes et aux systèmes coopératifs.

En France, différentes organisations soutiennent les recherches sur la sécurité routière telles que :

- des organisations régionales, exemple du GRRT (Groupement régionale de la Région Nord-Pas-de-Calais pour la Recherche dans les Transports),
- des organisations nationales telles que le Predit (« programme national de recherche d'expérimentation et d'innovation dans les transports terrestres », conduit, depuis 1990, par les ministères chargés de la recherche, des transports, de l'environnement et de l'industrie, l'ADEME et OSEO ANVAR [PRE_URL], les pôles de compétitivité (11 pôles de compétitivité transports terrestres ont été labellisés CIADT, « Comité interministériel pour l'aménagement et le développement du territoire », dont le pôle de compétitivité MOV'EO sur le thème « Des automobiles & transports collectifs sûrs pour l'homme et son environnement »).

Dans le cadre du PREDIT 2 puis 3, l'action ARCOS, montée par le Directeur de Recherche de l'INRETS Jean-Marc Blosseville, (« Action de Recherche pour une Conduite Sécurisée », 2002-2004) avait, en vue de réduire le nombre de tués de 30%, l'objectif d'accélérer le développement

des 4 fonctions d'aides à la conduite suivantes : « gérer les inter-distances entre véhicules ; prévenir les collisions sur obstacles fixes, arrêtés ou lents ; prévenir les sorties de route ; alerter les véhicules en amont d'accidents / incidents »). Cette action a fédéré un grand nombre de projet de recherche du Predit jusqu'en 2004 [ARC_URL].

En balayant quelques uns des projets et des organisations européennes et françaises, nous avons pu constater l'importance qu'ont prise, en presque 20 ans, les recherches pour une amélioration de la sécurité routière. Notons que ces efforts ne sont pas propres à l'Europe mais existent également par exemple au Japon et aux Etats-Unis.

Et quand est-il de l'évolution des capteurs depuis l'époque de PROMETHEUS ?

En 1992, malgré les difficultés technologiques la faisabilité de capteurs radar et lidar était démontré notamment en France à l'occasion du projet Prometheus-Prochip au moyen de prototypes expérimentaux (figure 3) conçus dans les laboratoires du CNRS à l'IEMN-DHS de Lille (radar hyperfréquence à balayage) par l'équipe du Professeur Roland et au LAAS de Toulouse par celle du Professeur Daniel Estève (capteur laser rotatif IR) [Estève, 1995]. Les problèmes d'intégration et de coût des technologies semblaient importants, de même que les difficultés de perte du signal lié au tangage. Aucun traitement de données n'était intégré dans ces capteurs. L'industrie, à cette époque, observait ces recherches mais ne s'y étaient pas encore engagé.

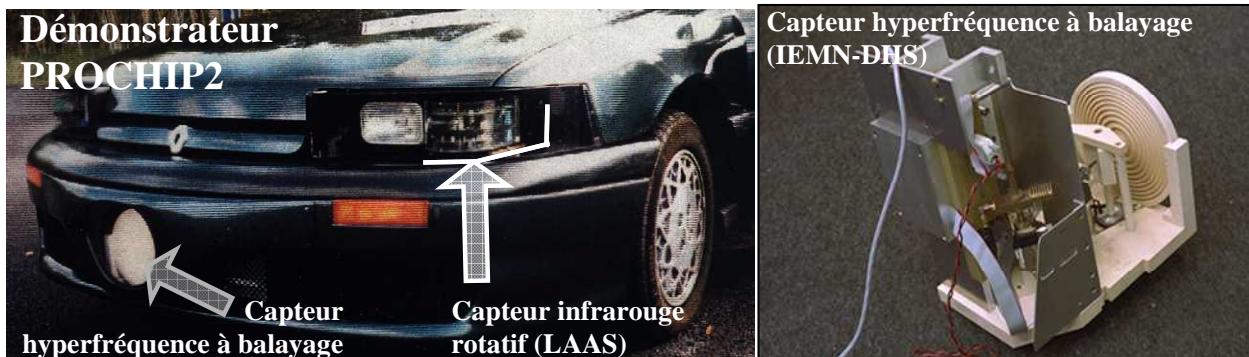


Figure 3 : Les capteurs rotatifs infrarouges et hyperfréquence à balayage du projet PROMETHEUS-PROCHIP France (1992).

A l'occasion des projets européens du 5^{ème} PCRD (1998-2002), les sociétés Thalès aéroporté et IBEO arrivaient dans les projets automobiles avec respectivement des capteurs radar et Lidar. Parmi les capteurs automobiles pouvant exister, le radar longue portée « AC10 » de première génération d'Autocruise [AUT_URL] (filiale commune à Thalès et TRW créée en 1998 et qui devient 100% TRW en 2003) était déjà en 2002 en phase de production en série avec traitement embarqué. Ce capteur ACC était capable d'être combiné à un système de contrôle de vitesse du véhicule. La production en série de la deuxième génération, AC 20 (taille 98x98x63 mm³), démarrait en avril 2005. Quant au capteur laserscanner d'IBEO, il sera vendu en série cet automne 2008 après avoir subi plusieurs phases de développement (voir § I.5.4) [IBEO_URL]. Afin d'illustrer les progrès depuis le programme PROMETHEUS en termes d'intégration de ces capteurs, la figure 4 montre une photo des capteurs AC10 d'Autocruise et Lux d'IBEO.



Radar AC10 (Autocruise, 2002)
taille 110x200x62mm³



Laser scanner Ibeo Lux (automne 2008)
taille 85x128x83mm³

Figure 4 : Les capteurs RADAR AC10 (Autocruise, 2002) et IBEO Lux (automne 2008).

En ce qui concerne l'usage de capteur vidéo, il est encore à l'état de recherche dans de nombreux projets. Un intérêt des industriels toujours présent existait pour un usage complémentaire de l'image et d'un capteur actif de type radar ou laser pour une amélioration de la détection d'obstacles routiers. À notre connaissance, il n'y a à ce jour pas de système commercialisé intégrant ces deux technologies dans l'embarqué.

SONAR	Capteur à ultra-son permettant le calcul de la distance entre l'objet détecteur et la cible par la mesure du temps aller-retour d'une impulsion ultrasonique	
	En complément du système ACC (aide au parking ou applications de détection courte portée dans le milieu urbain notamment)	
+/- :	Traitement des données simple Cout faible Faisabilité aisée	Mauvaise résolution angulaire (ouverture importante) Sensible aux bruits environnants Sensible aux conditions météorologiques Portée limitée Pratiquement inutilisable à des vitesses de quelques dizaines de m/s
CAMERAS PASSIVES	Solutions basées sur la comparaison de deux images prises simultanément par deux caméras embarquées sur le véhicule Couplée avec un radar ou lidar pour les détections courtes portées sur les autoroutes et l'amélioration des champs de visions latéraux de certaines catégories de véhicules tels que les bus et les camions	
+/- :	Faible coût Précision de l'image	Mesure distance/vitesse difficile Aveugles dans le brouillard et les projections de salissures dues à la route Sensibles aux salissures Portée limitée
LIDAR	Technologie basée sur un laser mono ou multifaisceaux dans l'infrarouge proche (longueur d'onde de 1.55 µm) Commercialisé notamment au Japon, mais peu fiable par temps à faible visibilité.	
+/- :	Faible coût Bonnes résolution et précision en distance Technologie maîtrisée Longue portée	Mesure distance/vitesse difficile Portée limitée par temps de brouillard et de pluie (atténuation > 100 dB/km) Sensibles aux salissures Interférences avec la lumière
RADAR millimétrique	Technologie basée sur l'émission d'ondes électromagnétiques du domaine millimétrique Commercialisé notamment au Japon, mais peu fiable par temps à faible visibilité.	
+/- :	Mesures simultanées de la distance, l'angle, la vitesse Capacités tout temps (pluie, brouillard, projections de la route...) Longue et courte portées	Pollutions électromagnétiques Interférences électromagnétiques Dimensionnement (conception) Coût de développement (nécessité de mettre en œuvre des technologies hyperfréquences intégrées MMIC)

Source [Piel, 2007]

Figure 5 : Limitations de technologie des capteurs de perception dans l'automobile [Piel, 2007]

Ainsi, les premiers systèmes ACC ont été commercialisés à la fin du 5^{ème} PCRD. Ces systèmes sont composés d'un capteur de type radar ou lidar et d'une unité de contrôle qui traite les informations de type objets/pistes fournies par le capteur et s'en serve soit pour informer le conducteur soit pour asservir la vitesse du véhicule et le maintenir à une distance de sécurité du véhicule précédent. Les limites de ces systèmes sont liées à celles des capteurs utilisés et le besoin en fusion d'information multicapteurs se fait à ce jour toujours sentir (figure 5).

I.2 Problématique scientifique étudiée

Le cadre de cette étude s'intègre donc dans une problématique d'assistance au conducteur où l'on cherche entre autres à prévenir au plus tôt le conducteur des dangers environnants éventuels en collaboration avec un système autonome d'anticollision à partir d'un ensemble de capteurs, et plus particulièrement d'un capteur actif de type télémètre à balayage.

Ces capteurs sont conçus pour effectuer un balayage angulaire de la scène (bidimensionnel ou tridimensionnel) et délivrent ainsi des mesures de distance radiale ρ et d'angle θ . Une des premières difficultés de ce genre de mesures réside dans la nature spatialement répartie d'un relevé de distance d'un objet. En effet, plusieurs points de mesure peuvent provenir en réalité d'un même objet. Il est donc nécessaire de réaliser, préalablement à tout traitement, une détection du nombre d'objets présents dans la scène. Cette étape, bien que non indispensable *a priori*, permet de limiter le nombre d'éléments à suivre dans la scène et ainsi de minimiser l'explosion combinatoire associée.

Dans un souci de conception d'un système d'anticollision automatisé, on pourrait se limiter à cette étape de détection d'objets et s'assurer alors que leur distance reste supérieure à une certaine distance de sécurité définie *a priori*. Toutefois, il est clair que cette politique ne peut être satisfaisante en pratique, en raison de la nécessité que l'on a de mettre en œuvre un système d'assistance à la conduite qui ait un comportement prédictif. Pour cela, il est indispensable d'envisager une estimation des paramètres dynamiques de l'objet observé. Les méthodes de filtrage statistique permettent de réaliser cette étape en exploitant les mesures disponibles à chaque instant.

Toutefois, une difficulté supplémentaire à notre cas d'étude repose sur sa nature « multi-objets » ou « multi-cibles » [Coué, 2003], [Labayrade, 2003]. On ne se trouve pas dans le cas d'un objet unique présent dans la scène, où l'on chercherait à dissocier les mesures utiles d'un éventuel fouillis inévitablement présent dans ce type de données, mais dans un cas général de suivi multi-objets. La difficulté est alors d'associer efficacement et à chaque instant les mesures disponibles à chaque objet présent dans la scène et permettre ainsi une estimation de leurs paramètres dynamiques.

La figure 6 montre l'enchaînement des différentes étapes nécessaires à la réalisation du suivi multi-objets. Après avoir réalisé l'acquisition des signaux par le **capteur à balayage**①, et la mise en forme de ces signaux en mesures (étape de **prétraitements**②), la première étape est donc la **détection**③, où il s'agit de séparer, parmi l'ensemble des mesures, celles qui proviennent des objets et d'en extraire certains paramètres prédéfinis des objets, afin de les transformer en informations potentielles nécessaires au processus de suivi. Ces informations sont alors mises en relation avec les objets détectés des instants précédents [Bar-Shalom, 1988], [Williams, 2003]. C'est l'étape **d'association temporelle**④. Les positions des objets précédemment détectés étant au préalable prédites, par le biais de l'étape de **prédition**⑤. C'est alors l'étape d'**estimation**⑥ qui, au travers

de ces mises en relation, permet d'estimer les nouveaux paramètres dynamiques des objets. L'étape de **suivi** ⑦ entre alors en action pour la gestion du suivi de ces objets (communément alors appelés pistes), où il s'agit de maintenir et mettre à jour les pistes déjà existantes et également de gérer les apparitions des nouvelles pistes et les disparitions de pistes existantes. Par ce processus, les paramètres dynamiques de l'ensemble des objets d'intérêt suivis sont alors fournis à chaque instant d'estimation, formant ainsi la scène des obstacles potentiels dans le champ d'observation du capteur placé sur le véhicule.

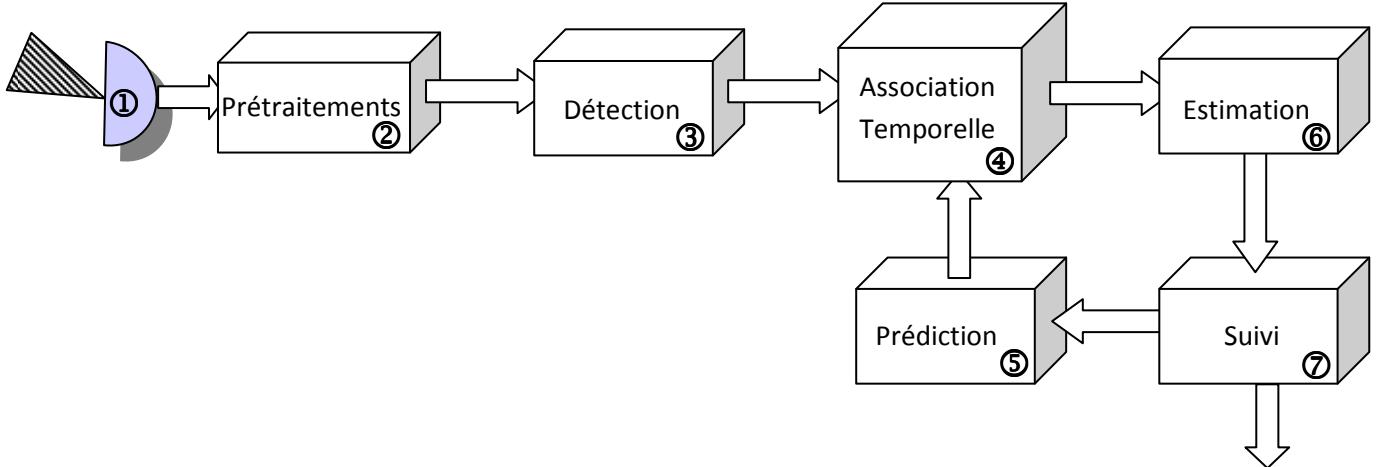


Figure 6 : Schéma général de perception et d'association multi-objets

C'est l'ensemble du processus de suivi que nous allons mettre en œuvre avec une attention particulière portée sur les étapes de détection et de l'association conjointe à l'estimation.

I.3 Méthode d'estimation

Le but de ce paragraphe est de rappeler la problématique de l'estimation dynamique de processus markoviens à temps discret. Dans le cas linéaire gaussien, la solution à ce problème conduit au filtre optimal de Kalman dont on fournit la description. Néanmoins dans le contexte plus général du filtrage non-linéaire, il n'existe plus de solution en dimension finie. On explore alors quelques-unes des solutions les plus courantes que sont le filtre de Kalman étendu (EKF) ou « Unscented » (UKF) et le filtrage particulaire.

I.3.1 Estimation dynamique de processus markoviens

Le principe de l'estimation dynamique consiste à évaluer récursivement l'évolution d'un processus X à partir d'un processus Z bruité, par lequel il est observé. On peut alors définir le problème de filtrage comme l'estimation du processus X à l'instant t lorsque l'on dispose des observations Z^τ jusqu'au temps $\tau = t$. Pour $\tau < t$ et $\tau > t$, on étend la notion de filtrage à celle respectivement de prédiction et de lissage dont les équations sont directement liées au problème de filtrage.

Le processus X est supposé markovien. Cette propriété se résume sous la forme suivante :

$$P(X(t) | X(t-1), X(t-2), \dots) = P(X(t) | X(t-1)) \quad (1)$$

Afin de poser la problématique du filtrage, on considère un système markovien à temps discret, modélisé par le système d'équations 2 :

$$\begin{cases} X(t) = F_t(X(t-1), \pi(t)) & (a) \\ Z(t) = H_t(X(t)) + \nu(t) & (b) \end{cases} \quad (2)$$

L'équation de dynamique 2-a décrit l'évolution temporelle du processus X et l'équation d'observation 2-b relie le processus à estimer au processus d'observation Z , où :

- F_t est la fonction de transition non-linéaire de l'état,
- $\pi(t)$ est la séquence de bruit blanc de dynamique dont la loi est connue,
- H_t est la fonction d'observation, également non-linéaire,
- $\nu(t)$ est la séquence de bruit blanc d'observation de loi connue.

La résolution du problème de filtrage s'effectue en construisant un estimateur qui optimise un critère dont le choix est dicté par le contexte. Au sens de ce critère, on note alors $\hat{X}(t|t)$ l'estimateur optimal de l'état du processus X à l'instant t , connaissant les mesures jusqu'à l'instant t .

On s'intéresse par la suite à l'estimateur au sens du minimum d'erreur quadratique moyenne. Dans ce cas, l'estimateur $\hat{X}(t|t)$ s'écrit :

$$\begin{aligned} \hat{X}(t|t) &= E[X(t)|Z^t] = \int_{X^t} X(t) P(X^t|Z^t) dX^t \\ &= \int_{X(t)} X(t) P(X(t)|Z^t) dX(t) \end{aligned} \quad (3)$$

Il convient de remarquer que la solution repose uniquement sur la connaissance de la densité de probabilité conditionnelle $P(X(t)|Z^t)$.

La nature dynamique du système décrit précédemment implique un nombre d'observations Z^t croissant avec le temps. Il est donc nécessaire d'établir des relations permettant d'estimer récursivement cette densité de probabilité.

On montre que cette récursivité se décompose en deux étapes :

- une partie prédictive fondée sur l'équation de dynamique (2-a), afin d'engendrer *a priori* la densité de probabilité à l'instant t , connaissant les $t-1$ dernières observations. On utilise pour cela l'équation de Chapman-Kolmogorov :

$$P(X(t)|Z^{t-1}) = \int_{X(t-1)} P(X(t)|X(t-1)) P(X(t-1)|Z^{t-1}) dX(t-1) \quad (4)$$

- une partie corrective reposant sur la règle de Bayes (et sur les propriétés de markovienneté des processus étudiés) :

$$P(X(t)|Z^t) = \frac{P(Z(t)|X(t)) P(X(t)|Z^{t-1})}{P(Z(t)|Z^{t-1})} \quad (5)$$

Par récurrence on trouve que :

$$P(X(t)|Z^t) = \frac{\int_{X^{t-1}} \prod_{\tau=1}^t P(X(\tau)|X(\tau-1)) P(X(0)) \prod_{\tau=0}^t P(Z(\tau)|X(\tau)) dX^{t-1}}{\int_{X^t} \prod_{\tau=1}^t P(X(\tau)|X(\tau-1)) P(X(0)) \prod_{\tau=0}^t P(Z(\tau)|X(\tau)) dX^t} \quad (6)$$

En résumé, la relation (6) montre que le filtrage des processus markoviens à temps discret repose sur deux densités de probabilités :

- une loi de transition $P(X(t)|X(t-1))$ de l'état $X(t-1)$ à l'instant $t-1$ vers l'état $X(t)$ à l'instant t ;
- une loi d'observation $P(Z(t)|X(t))$.

On retrouvera ces deux étapes élémentaires dans l'ensemble des méthodes de filtrage détaillées par la suite.

I.3.2 Filtrage linéaire optimal : le filtre de Kalman

C'est en 1960 que R.E. Kalman introduit l'algorithme [Kalman, 1960] qui porte son nom. Cet algorithme permet la mise en œuvre optimale des équations de filtrage en se basant sur l'hypothèse linéaire /gaussienne. Les équations du modèle d'état, supposées linéaires et les bruits, additifs gaussiens, garantissent que la loi de probabilité conditionnelle soit également gaussienne. Le problème de filtrage est donc de dimension finie et il se résume au calcul récursif des deux premiers moments de cette loi, qui la définissent complètement.

Soit le système à temps discret, décrit par le modèle d'état linéaire suivant :

$$\begin{cases} X(t) = F_t X(t-1) + K(t) W(t) \\ Z(t) = H_t X(t) + V(t) \end{cases} \quad (7)$$

où :

- $X(t)$ est le vecteur d'état, observé par $Z(t)$ à l'instant t ,
 - F_t , H_t sont les matrices de dynamique et d'observation du système,
 - $K(t)$ est la matrice de gain,
 - $W(t)$ et $V(t)$ sont des bruits blancs gaussiens additifs de moyenne nulle et de matrices de covariance respectives $Q(t)$ et $R(t)$. Ces bruits sont supposés indépendants,
- $$E[W(t)V(t)^T] = 0.$$

L'algorithme qui en découle est présenté dans la figure 7, en prenant $\hat{X}(0|0) = X(0)$ et $P(0|0) = P(0)$ comme conditions initiales où $X(0)$ est une variable aléatoire gaussienne de moyenne $E[X(0)] = \bar{X}(0)$ et de covariance $P(0)$.

Le filtre de Kalman peut donc se décomposer en deux étapes :

- une étape de prédition qui exploite l'équation de dynamique du système pour estimer le vecteur d'état $X(t)$ à l'instant t et la covariance d'erreur de prédition associée.
- une étape de correction qui exploite les mesures disponibles à l'instant t pour corriger l'estimation précédente.

Prédiction :

- prédition de l'état : $\hat{X}(t|t-1) = F_t \hat{X}(t-1|t-1)$
- covariance de l'erreur de prédition : $P(t|t-1) = F_t P(t-1|t-1) F_t^T + Q(t)$

Correction :

- correction de l'état : $\hat{X}(t|t) = \hat{X}(t|t-1) + K(t)(Z(t) - H_t \hat{X}(t|t-1))$
- covariance de l'erreur d'estimation : $P(t|t) = (I - K(t) H_t) P(t|t-1)$
- gain du filtre : $K(t) = P(t|t-1) H_t^T \left(\underbrace{H_t P(t|t-1) H_t^T + R(t)}_{S(t)} \right)^{-1}$

avec $S(t)$ la matrice d'innovation.

Figure 7 : Filtre de Kalman.

A noter que la correction apportée à l'état prédit est pondérée par la matrice de gain $K(t)$ dont l'interprétation est la suivante :

- un état prédit peu précis et une mesure précise impliquent un grand gain $K(t)$ et par conséquent une grande correction apportée, traduisant une confiance de l'estimateur dans les mesures ;
- une mesure peu précise et un état prédit précis impliquent un faible gain $K(t)$, l'estimateur aura cette fois confiance dans le modèle dynamique.

En dehors du cadre gaussien, le filtre de Kalman est encore l'estimateur optimal dans la classe des filtres linéaires. Par contre l'abandon de l'hypothèse linéaire (voir équation 2) rend le filtre inutilisable tel quel. Il faut donc se tourner vers d'autres approches en sachant qu'il n'existe plus de solution récursive en dimension finie.

I.3.3 Filtrage non-linéaire

Nous présentons par la suite trois approches dont l'objectif est de traiter des modèles non-linéaires.

Nous présentons tout d'abord deux filtres basés sur le filtre de Kalman détaillé précédemment :

- le filtre de Kalman étendu qui repose sur une linéarisation des équations d'état.

- le filtre de Kalman « Unscented » qui exploite la transformation mathématique du même nom pour délivrer une estimation des deux premiers moments de la densité de probabilité conditionnelle, solution du problème de filtrage.

Nous finissons par une présentation du principe des méthodes de Monte Carlo séquentielles dont l'avantage, contrairement aux méthodes précédentes, est de délivrer directement une estimation de la densité de probabilité conditionnelle et non plus de ses deux premiers moments uniquement.

I.3.3.1 Le filtre de Kalman étendu

Parmi les algorithmes de filtrage non-linéaire, le filtre de Kalman étendu (EKF) est la solution la plus directe [Anderson, 1979][Bar-Shalom, 1993]. On se ramène au cas linéaire du filtre de Kalman en prenant un développement de Taylor au premier ordre des équations du modèle autour de l'estimation courante :

$$\begin{aligned} F_t(X(t-1)) &\approx F_t(\hat{X}(t-1|t-1)) + f_t(X(t-1) - \hat{X}(t-1|t-1)) \\ H_t(X(t-1)) &\approx H_t(\hat{X}(t-1|t-1)) + h_t(X(t-1) - \hat{X}(t-1|t-1)) \end{aligned} \quad (8)$$

où f_t et h_t sont les jacobiniennes respectives des fonctions non-linéaires de dynamique F_t et d'observation H_t (figure 8).

Prédiction :

- Prédiction de l'état : $\hat{X}(t|t-1) = F_t(\hat{X}(t-1|t-1))$
- Covariance de l'erreur de prédiction : $P(t|t-1) = f_t P(t-1|t-1) f_t^T + Q(t)$

Correction :

- Correction de l'état : $\hat{X}(t|t) = \hat{X}(t|t-1) + K(t)(Z(t) - H_t \hat{X}(t|t-1))$
 - Covariance de l'erreur d'estimation : $P(t|t) = (I - K(t)h_t)P(t|t-1)$
 - Gain du filtre : $K(t) = P(t|t-1)h_t^T (h_t P(t|t-1) h_t^T + R(t))^{-1}$
- Avec f_t et h_t , jacobiniennes de F_t et H_t

$$f_t = \left. \frac{\partial F_t(X(t))}{\partial X(t)} \right|_{X(t)=\hat{X}(t-1|t-1)} \quad h_t = \left. \frac{\partial H_t(X(t))}{\partial X(t)} \right|_{X(t)=\hat{X}(t|t-1)}$$

Figure 8 : Filtre de Kalman étendu.

L'approximation d'un modèle non-linéaire par son équivalent linéarisé est convenable en supposant que les non-linéarités soient faibles et que la cadence d'échantillonnage soit suffisamment élevée pour que l'erreur d'approximation soit minime. Si ces conditions ne sont pas respectées, le filtre peut être mis en défaut ou avoir un comportement instable. Des raffinements de l'algorithme existent [Jazwinsky, 1970], qui utilisent des approximations d'ordres supérieurs ou un traitement itératif (Iterated Kalman Filter).

I.3.3.2 Le filtre de Kalman « Unscented »

Le filtre de Kalman « Unscented » (UKF) [Julier, 1997] est l'une des plus récentes évolutions du filtre de Kalman et se présente en alternative à l'EKF. L'idée est qu'il est plus facile d'approximer une densité de probabilité que d'approximer une fonction non-linéaire. En abandonnant l'étape de linéarisation, le filtre permet d'utiliser directement les équations non-linéaires. La densité de probabilité gaussienne est décrite par un nuage déterministe de points dans l'espace d'état. Les deux premiers moments de la loi sont calculés en soumettant simplement ce nuage aux équations d'états non-linéaires. Si la loi n'est pas gaussienne, la méthode permet d'obtenir les deux premiers moments de cette loi de manière exacte.

Initialisation :	$\sigma_i(t-1 t-1), i=1, \dots, 2n$
$\hat{X}_a(t-1) = \begin{bmatrix} \hat{X}(t-1) & 0 & 0 \end{bmatrix}^T, P_a(t-1 t-1) = \begin{bmatrix} P(t-1 t-1) & 0 & 0 \\ 0 & Q & 0 \\ 0 & 0 & R \end{bmatrix}$	Colonne i de $\pm\sqrt{(n+\lambda)P(t-1 t-1)}$
$\chi^0(t-1 t-1) = \hat{X}_a(t-1 t-1)$ Etat initial du filtre	$\chi^i(t-1 t-1) = \hat{X}_a(t-1 t-1) + \sigma_i(t-1 t-1)$ Etats initiaux des sigma-points
$\omega_0 = \frac{\lambda}{n+\lambda}$ Pondération de l'état initial	$\omega_i = \frac{1}{2(\lambda+n)}$ Pondération des sigma-points
Prédiction :	$\hat{X}(t t-1) = \sum_{i=0}^{2n} \omega_i F_t(\chi^i(t t-1))$ Prédiction de l'état
$P(t t-1) = \sum_{i=0}^{2n} \omega_i [\chi^i(t t-1) - \hat{X}(t t-1)] [\chi^i(t t-1) - \hat{X}(t t-1)]^T + Q(t)$ Covariance prédite	$\hat{Z}(t t-1) = \sum_{i=0}^{2n} \omega_i H_t(\chi^i(t t-1))$ Mesure prédite
Correction : $P_{\hat{Z}(t)\hat{Z}(t)} = \sum_{i=0}^{2n} \omega_i [H_t(\chi^i(t t-1)) - \hat{Z}(t t-1)] [H_t(\chi^i(t t-1)) - \hat{Z}(t t-1)]^T + R(t)$ Covariance de la mesure	
$P_{\hat{X}(t)\hat{Z}(t)} = \sum_{i=0}^{2n} \omega_i [F_t(\chi^i(t-1 t-1)) - \hat{X}(t t-1)] [H_t(\chi^i(t t-1)) - \hat{Z}(t t-1)]^T$ Covariance état/mesure	
$P(t t) = P(t t-1) - K(t) P_{\hat{Z}(t)\hat{Z}(t)} K(t)^T$ Correction de la covariance	$\hat{X}(t t) = \hat{X}(t t-1) + K(t)(Z(t) - \hat{Z}(t t-1))$ Correction de l'estimée
$K(t) = P_{\hat{X}(t)\hat{Z}(t)} P_{\hat{Z}(t)\hat{Z}(t)}^{-1}$ Gain du filtre	

Figure 9 : Filtre de Kalman « Unscented ».

Une itération du filtre de Kalman « Unscented » se déroule en trois étapes (figure 9) :

- **l'initialisation** : elle consiste à définir $2n+1$ « sigma points » issus de la covariance $P(t-1|t-1)$. Le vecteur $\chi^0(t-1|t-1)$ correspond à l'estimée de l'itération précédente. ω est un terme de pondération où λ est un coefficient qui module l'importance de l'état estimée dans les calculs ;
- **la prédition** : les « sigmas points » évoluent dans l'espace d'état et leur somme pondérée permet de calculer l'état, la covariance et la mesure prédictive avec les équations non linéaires ;
- **la correction** : d'une manière similaire au filtre de Kalman, le gain du filtre est calculé et permet de corriger l'état et la covariance prédictives.

Le filtre de Kalman « Unscented » montre généralement des performances supérieures au filtre de Kalman étendu [Wan, 2001] ou tout au moins des performances égales [Laviola, 2003].

I.3.3.3 Méthodes de Monte-Carlo séquentielles : l'approche particulaire

Principe

L'objectif consiste à approximer la densité de probabilité conditionnelle $P(X(t)|Z^t)$ par une approche de type Monte-Carlo. En simulant un grand nombre de vecteurs aléatoires $X_i(t)$, $i=\{1, \dots, N\}$ (appelés particules en raison de leur caractère dynamique [Doucet, 2002]) suivant $P(X(t)|Z^t)$, il est possible de construire une approximation de cette loi. A chaque itération, les particules explorent indépendamment l'espace d'état suivant le flot du système et sont pondérées avec la mesure fournie à l'instant t .

Les méthodes de Monte-Carlo séquentielles nécessitant beaucoup de ressources calculatoires, leur utilisation n'est devenue réellement possible que vers la fin des années 80 avec la montée en puissance des moyens informatiques. Elles sont apparues indépendamment sous les désignations de filtrage particulaire [Moral, 1993], filtrage bootstrap [Gordon, 1993], algorithme de condensation [Isard, 1998], que l'on retrouve dans de nombreux domaines tels que la navigation [Carvalho, 1997][Nordlund, 2002][Flament, 2004], la vision [Isard, 1998][Lanvin, 2004], le traitement audionumérique du signal [Vermaak, 2000][Cemgil, 2003], etc.

La difficulté dans ce genre d'approche réside dans le fait qu'il est rarement possible d'échantillonner suivant $P(X(t)|Z^t)$. Pour cette raison, il est nécessaire d'utiliser une autre densité de probabilité $\pi(X(t)|Z^t)$ appelée densité d'importance qui contient le support de $P(X(t)|Z^t)$ et selon laquelle il est possible d'échantillonner. L'algorithme qui en découle est dénommé Sequential Importance Sampling (SIS) [Doucet, 1998][Arulampalam, 2002].

Le second obstacle rencontré dans ces méthodes est le comportement dégénéréscent des particules : après quelques itérations, les poids de certaines particules ont tendance à devenir très faibles en comparaison aux autres. Par conséquent, ces particules contribuent faiblement à l'estimateur, qui suppose des poids proches de $1/N$, conformément à la loi des grands nombres. Plusieurs solutions ont été proposées pour pallier cet inconvénient. Il est possible d'introduire un noyau régularisant

dans la pondération qui n'utilise, par exemple, que les mesures appartenant à une fenêtre (rectangulaire, exponentielle) [Moral, 1994][Doucet, 2002].

Cependant, une telle procédure ne suffit pas à assurer la convergence de l'algorithme dans un cas général. On introduit généralement une étape de redistribution statistique qui joue également un rôle régularisant sur les pondérations. Pendant cette étape, les particules de poids les plus forts auront d'autant plus de chance de se multiplier et les particules de poids faibles auront tendance à disparaître. Dans la littérature, l'algorithme basique intégrant un schéma de redistribution est appelé Sequential Importance Resampling (SIR).

Echantillonnage d'importance

La solution du problème de filtrage est définie comme l'espérance de l'état conditionnelle aux mesures disponibles jusqu'à l'instant t :

$$\hat{X}(t|t) = \int_{X(t)} X(t) P(X(t)|Z^t) dX(t) \quad (9)$$

Hormis quelques cas particuliers (dont le cas linéaire gaussien), l'intégrale précédente est en pratique impossible à calculer analytiquement. Le problème de filtrage étant essentiellement basé sur la connaissance de $P(X(t)|Z^t)$, les méthodes particulières proposent d'en établir une approximation discrète pour permettre d'évaluer numériquement cette équation.

Le principe du filtrage particulaire repose sur une approximation de type de Monte-Carlo [Arulampalam, 2002][Doucet, 2002] qui consiste à construire une approximation de la densité de probabilité $P(X|Z^t)$ en générant un grand nombre de variables aléatoires X_i , $i = \{1, \dots, N\}$ indépendantes et identiquement distribuées suivant cette loi. La densité de probabilité discrète résultante est dessinée par N mesures de Dirac équipondérées de support X_i , qui représentent chacune un point de l'espace d'état :

$$P_N(X(t)|Z^t) = \frac{1}{N} \sum_{i=1}^N \delta_{X_i(t)}(X(t)) \quad (10)$$

En remplaçant dans l'équation (9) la loi P par son approximation P_N , il vient :

$$\hat{X}(t|t) \approx \int_{X(t)} X(t) \frac{1}{N} \sum_{i=1}^N \delta_{X_i(t)}(X(t)) dX(t) = \frac{1}{N} \sum_{i=1}^N X_i(t) \quad (11)$$

La loi faible des grands nombres permet en outre d'assurer que l'approximation de la loi de probabilité converge vers la véritable loi lorsque $N \rightarrow \infty$

$$\lim_{N \rightarrow \infty} P_N(X(t)|Z^t) = P(X(t)|Z^t) \quad (12)$$

L'avantage des tirages de Monte-Carlo est clair : dès lors que l'on sait générer des variables aléatoires suivant une loi, l'intégrale (9) se transforme en une simple somme dont la précision dépend du nombre d'échantillons N . Malheureusement, cette solution est seulement conceptuelle car dans la plupart des cas, cette loi n'est pas connue *a priori* et ne permet donc pas le calcul de $\hat{X}(t|t)$.

Pour contourner ce problème, plusieurs approches sont possibles [Doucet, 2002][Moral, 2004]. L'une des plus courantes est l'échantillonnage d'importance [Gordon, 1993][Moral, 1993][Doucet, 1998]. L'idée est d'utiliser une autre densité de probabilité $Q(X(t)|Z^t)$ pour laquelle il est facile d'échantillonner. Le choix de cette fonction n'est pas anodin, son support doit au moins contenir celui de $P(X(t)|Z^t)$:

$$P(X(t)|Z^t) > 0 \Rightarrow Q(X(t)|Z^t) > 0 \quad (13)$$

et si possible, avoir un comportement proche de $P(X(t)|Z^t)$.

La densité de probabilité $Q(X(t)|Z^t)$ est introduite dans (9), et l'espérance conditionnelle est réécrite sous la forme suivante :

$$\hat{X}(t|t) = \int_{X(t)} X(t) \frac{P(X(t)|Z^t)}{Q(X(t)|Z^t)} Q(X(t)|Z^t) dX(t) \quad (14)$$

ou encore :

$$\hat{X}(t|t) = \int_{X(t)} X(t) \varphi^*(t) Q(X(t)|Z^t) dX(t), \quad \varphi^*(t) = \frac{P(X(t)|Z^t)}{Q(X(t)|Z^t)} \quad (15)$$

qui permet de se ramener aux conditions de (9). L'approximation appliquée conduit à la nouvelle expression de l'espérance conditionnelle :

$$\hat{X}(t|t) = \sum_{i=1}^N X_i(t) \varphi_i^*(t) \quad (16)$$

Le terme $\varphi_i^*(t)$ est appelé poids d'importance de la variable aléatoire $X_i(t)$. Lorsque l'on développe ce terme à l'aide de la formule de Bayes, on obtient :

$$\varphi_i^*(t) = \frac{P(Z^t | X_i(t)) P(X_i(t))}{P(Z^t) Q(X_i(t)|Z^t)} \quad (17)$$

On remarque dans l'équation précédente que l'évaluation des poids implique la connaissance de $P(Z^t)$ qui n'est généralement pas accessible. Une manière de corriger ce problème consiste à normaliser les poids :

$$\varphi_i(t) = \frac{\varphi_i^*(t)}{\sum_{j=1}^N \varphi_j^*(t)} \quad (18)$$

On trouve dans [Doucet, 2002] une description des fonctions d'importance les plus courantes.

Equations générales du filtrage particulaire (SIS)

En résumé, le filtrage particulaire est construit autour de deux étapes élémentaires :

- une étape d'évolution des particules $X_i(t)$ selon le flot stochastique du système ;
- une étape de calcul des pondérations $p_i(t)$ à partir des équations de capteur.

S'appuyant sur la formulation récursive des équations de filtrage, on retrouve dans ces deux étapes des dépendances avec les lois de transition $P(X(\tau)|X(\tau-1))$ et d'observation $P(Z(\tau)|X(\tau))$. Dans la littérature, cette structure de filtre est appelée algorithme d'échantillonnage séquentiel pondéré [Doucet, 1998] ou procédure d'exploration/pondération.

L'algorithme qui découle des considérations précédentes (figure 10) se déroule de la manière suivante :

- **l'initialisation** : les N particules $X_i(0)$ sont reparties dans l'espace d'état suivant l'information initiale disponible $P(X(0))$;
- **la prédiction** : chaque particule évolue dans l'espace d'état suivant l'équation de dynamique du système :

$$X_i(t) = F_t(X_i(t-1), \pi_i(t)) \quad i = \{1, \dots, N\} \quad (19)$$

Initialisation :	$X_i(0), i = \{1, \dots, N\}$	$p_i(0) = \frac{1}{N}$
Initialisation des particules		Initialisation des poids associés
Prédiction :	$X_i(t) = F_t(X_i(t-1), \pi_i(t))$	
Evolution des particules suivant le flot stochastique		
Pondération :	$p_i(t) = p_i(t-1) \frac{P(Z(t) X_i(t))}{\sum_{j=1}^N P(Z(t) X_j(t))}$	
Mise à jour et normalisation des poids		
Estimation :	$\hat{X}_N(t t) = \sum_{i=1}^N p_i(t) X_i(t)$	
Estimation de l'état		

Figure 10 : Filtrage particulaire (SIS).

- **la pondération** : la pondération permet d'évaluer la probabilité associée aux trajectoires pour chaque particule. Un poids $p_i(t) \in [0, 1]$ est calculé pour chaque particule à l'aide de la loi d'observation :

$$p_i(t) = \frac{\prod_{\tau=0}^t P(Z(\tau)|X_i(\tau))}{\sum_{l=1}^N \prod_{\tau=0}^t P(Z(\tau)|X_l(\tau))} \quad (20)$$

ou sous forme récursive :

$$p_i(t) = \frac{P(Z(t) | X_i(t))}{\sum_{l=1}^N P(Z(t) | X_l(t))} p_i(t-1) \quad (21)$$

- **l'estimation** : l'ensemble des particules dessine une approximation de la loi conditionnelle $P(X(t) | Z^t)$ et l'estimation se calcule par :

$$\hat{X}(t | t) = E[X(t) | Z^t] = \int_{X(t)} X(t) P(X(t) | Z^t) dX(t) \quad (22)$$

En utilisant l'approximation particulaire,

$$\hat{X}(t | t) \approx \int X(t) \sum_{i=1}^N p_i(t) \delta_{X_i(t)}(X(t)) dX(t) \quad (23)$$

L'estimation devient :

$$\hat{X}(t | t) = \sum_{i=1}^N p_i(t) X_i(t) \quad (24)$$

Pour un traitement dynamique, on itère à chaque instant les étapes de prédiction, de pondération et d'estimation.

Filtrage particulaire avec redistribution (SIR)

Dans l'approche précédente, même si la convergence est assurée pour N grand, on ne garantit en rien la meilleure utilisation possible de ces particules. En effet, bien que chaque particule apporte sa contribution à l'estimateur, de fortes disparités sur leurs pondérations peuvent subsister. Ce comportement peut poser des problèmes d'optimalité de l'application de la loi des grands nombres qui nécessite des poids proches de $\frac{1}{N}$.

Pour éviter cela, on utilise des méthodes de redistribution statistique. Elles consistent à distribuer les N particules dans l'espace d'état, selon les poids $p_i(t)$ de chaque support $X_i(t)$. Les particules « lourdes » donnent naissance à davantage de particules alors que les particules « légères » disparaissent. Lorsque cette procédure est effectuée, les poids des particules sont réinitialisés à $\frac{1}{N}$.

La structure du filtre particulaire reste sensiblement identique au cas précédent :

- **l'initialisation** : identique à SIS.
- **la prédiction** : identique à SIS.
- **la pondération** : identique à SIS.
- **l'estimation** : identique à SIS.
- **la redistribution** : la redistribution est utilisée tous les T instants, et les poids des particules sont remises à $\frac{1}{N}$.

La figure 11 présente les grandes lignes de l'algorithme particulaire avec redistribution.

Initialisation :	$X_i(0), i = \{1, \dots, N\}$	$p_i(0) = \frac{1}{N}$
	Initialisation des particules	Initialisation des poids associés
Prédiction :	$X_i(t) = F_t(X_i(t-1), \pi_i(t))$	Evolution des particules suivant le flot stochastique
Pondération :	$p_i(t) = p_i(t-1) \frac{P(Z(t) X_i(t))}{\sum_{j=1}^N P(Z(t) X_j(t))}$	Mise à jour et normalisation des poids
Estimation :	$\hat{X}_N(t t) = \sum_{i=1}^N p_i(t) X_i(t)$	Estimation de l'état
Redistribution :	$p_i(t) = \frac{1}{N}$	Redistribution des poids tous les T instants

Figure 11 : Filtrage particulaire avec redistribution (SIR).

Il existe de nombreuses politiques de redistribution quant à leur périodicité T , à leur loi de distribution et à leur réalisation pratique. On trouvera pour cela plus de détails dans [Doucet, 2002].

I.4 Association Temporelle de données

I.4.1 Introduction

Dans un système de poursuite multi-objets, l'étape d'association temporelle est un point délicat. Elle identifie dans le temps les objets présents dans la scène. Une mauvaise association entraîne pour l'ensemble de l'algorithme de suivi une erreur sur l'estimation des trajectoires des objets.

L'estimation des caractéristiques dynamiques des objets est un problème classique des systèmes de suivi d'objets multiples. Pour réaliser cette estimation, le rôle de l'étape d'association temporelle est de mettre en relation les informations (mesures) de l'instant courant avec celles des instants précédents (figure 12). Les informations de l'instant courant sont issues de l'étape de détection d'objets et constituent le jeu de mesures disponibles pour assurer l'étape de suivi. L'exploitation des instants précédents passe par une étape de prédiction dans laquelle les informations dont on dispose sont exploitées afin de prévoir l'information attendue à l'instant courant et d'assurer ainsi l'association entre données attendues et données disponibles. Au final, l'étape de filtrage n'aura

plus qu'à intégrer le résultat de cette association pour affiner l'estimation des états des objets (position, vitesse...).

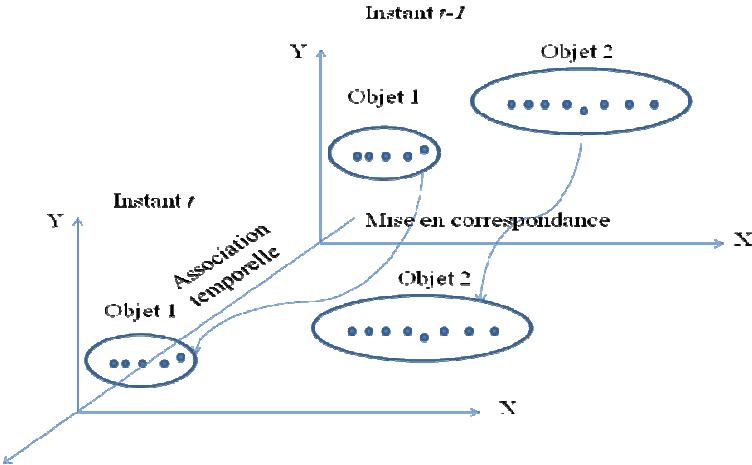


Figure 12: Principe de l'association temporelle (entre deux instants successifs).

Dans un contexte multi capteurs, l'étape d'association est cruciale car elle conditionne le bon déroulement de l'ensemble de la chaîne d'estimation et de suivi. Toutefois, afin de garantir une association efficace entre les objets mesurés à l'instant t et les objets prédits à partir des informations aux instants précédents, il convient de définir une région de validité autour de la position prédite $\hat{Z}_i(t | t-1)$ d'une piste i . Cela permet de décider s'il y a lieu d'associer la piste existante avec une ou plusieurs observations à l'instant courant. Plusieurs cas de figure peuvent se présenter :

- une unique observation se trouve dans la région de validité de la piste,
- plusieurs observations tombent dans la région de validité d'une seule piste,
- une ou plusieurs observation(s) appartiennent à plus d'une région de validité de pistes.

Nous détaillons par la suite les principales méthodes d'association temporelle. Le paragraphe I.4.2 considère tout d'abord le cas mono-objet avec une mise en correspondance des objets piste par piste et présente quelques approches :

- méthode du Plus Proche Voisin (NN –*Nearest Neighbors*) : sélection de l'observation la plus proche en distance de la mesure prédite, pour une piste donnée ;
- méthode d'Association Probabiliste de Données (PDA –*Probabilistic Data Association*) : sélection de toutes les observations qui peuvent être à l'origine de la piste en cours de traitement ;

Le paragraphe I.4.3 traite du cas multi-objets où cette fois les pistes et les observations sont étudiées simultanément. On distingue deux méthodes principales :

- méthode MHT (*Multiple Hypothesis Tracking*) : association de chaque piste avec les mesures disponibles à l'instant courant. Trois hypothèses sont envisageables : soit elle est à l'origine d'une piste antérieurement existante, soit elle est à l'origine d'une nouvelle piste, soit il s'agit d'une fausse alarme (clutter, etc.) ;

- méthode d’Association Probabiliste Conjointe de Données (JPDA –*Joint Probabilistic Data Association*) : association de l’ensemble des pistes antérieurement existantes avec toutes les mesures disponibles à l’instant courant.

I.4.2 Méthodes d’association de données mono-objet

I.4.2.1 Méthode du plus proche voisin (NN)

La méthode NN passe par le calcul d’une distance statistique entre l’observation prédictive pour la piste i et l’ensemble des mesures disponibles à l’instant courant. Le principe est alors d’associer l’observation $Z_j(t)$ la plus proche en distance à la piste i étudiée.

La métrique utilisée pour cette méthode est la métrique de Mahalanobis. Elle permet de prendre en compte les erreurs de prédiction sur la mesure $\hat{Z}_i(t|t-1)$ pour la piste i ainsi que celles liées aux observations $Z_j(t)$ à l’instant courant. Ces erreurs sont quantifiées par la matrice $P(t|t-1)$ de covariance de l’erreur de prédiction délivrée par l’étape de filtrage et par la matrice $R_j(t)$ de covariance d’erreur de mesure directement liée au capteur et donc également à l’étape de détection. La distance de Mahalanobis est donc une distance statistique qui prend en compte les erreurs du système de perception et celles du processus de suivi.

La distance de Mahalanobis entre la mesure prédictive pour la piste i et l’observation j est décrite par :

$$\begin{aligned} d_{ij}^2 &= (Z_j(t) - \hat{Z}_i(t|t-1))^T S_i^{-1}(t) (Z_j(t) - \hat{Z}_i(t|t-1)) \\ &= \tilde{Z}_{ij}(t|t-1)^T S_i^{-1}(t) \tilde{Z}_{ij}(t|t-1) \end{aligned} \quad (25)$$

où $S_i(t)$ est la matrice d’innovation définie par $S_i(t) = H_t P_i(t|t-1) H_t^T + R(t)$ (26)

et $\tilde{Z}_{ij}(t|t-1) = Z_j(t) - \hat{Z}_i(t|t-1)$ (27)

est le processus d’innovation entre la piste i et l’observation j .

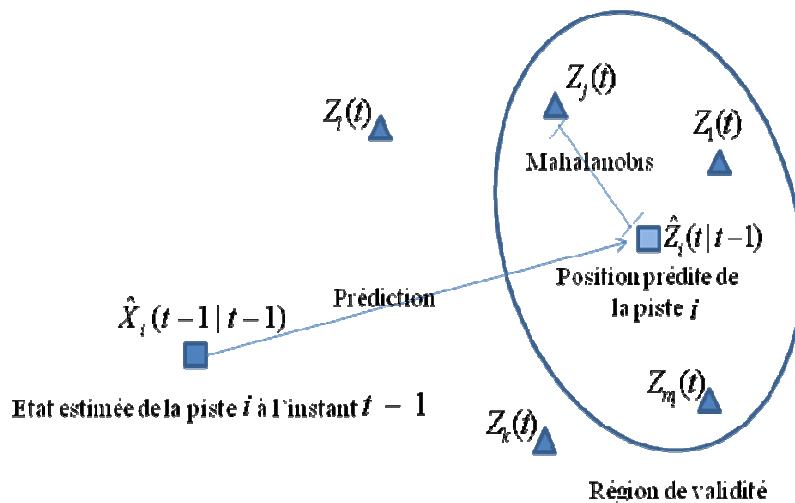


Figure 13 : Principe de la méthode NN.

La figure 13 illustre le principe de la méthode NN où l'on choisit de sélectionner, à l'intérieur de la région de validité, la mesure dont la distance de Mahalanobis est la plus faible. Cette méthode relativement simple à mettre en œuvre est détaillée dans [Bar-Shalom, 1988] et [Blackman, 1986].

On peut remarquer qu'il existe de multiples raisons pour lesquelles le processus d'association peut ne pas fonctionner. Outre la stabilité de l'étape de filtrage, la principale difficulté provient du capteur qui peut délivrer des informations non directement liées aux objets présents dans la scène (fausse alarme) voire ne pas en délivrer (non détection). Ces deux notions sont centrales dans les systèmes de suivi multi cibles.

I.4.2.2 Méthode d'association probabiliste de données (PDA)

Dans la méthode NN, on retient pour chaque piste l'observation la plus proche, au sens de la distance de Mahalanobis, afin de mettre à jour l'état. Cette étape peut parfois conduire à un choix erroné qui risque d'entraîner une erreur sur l'estimation de la piste considérée.

La méthode PDA permet de résoudre ce problème en intégrant, non plus une seule, mais l'ensemble des observations candidates à l'association. Une observation $Z_j(t)$ est considérée comme candidate pour la mise à jour, si elle appartient à la région de validité définie par la matrice d'innovation $S_i(t)$.

Cette approche nécessite de reformuler le filtre associé, car il doit intégrer l'ensemble des observations $Z(t)$ incluses dans la région de validation.

La solution consiste à construire l'estimateur global à partir d'estimateurs locaux relatifs à chaque hypothèse d'association (mesures candidates $\{Z_j(t)\}_{j=1, \dots, m_i}$). L'estimateur global est alors la somme pondérée par des coefficients α_{ij} (cf. § Estimation d'état), des estimateurs locaux. Les coefficients α_{ij} , appelés probabilités d'association, intègrent notamment la probabilité de détection P_D .

Région de validité

De manière identique à la méthode NN, la méthode PDA propose de définir une région de validité autour de la mesure prédite $\hat{Z}_i(t|t-1)$ de chaque piste. On calcule ensuite la probabilité d'association entre la position prédite $\hat{Z}_i(t|t-1)$ et chaque observation $Z_j(t)$ qui tombe dans la région de validité selon la distance de Mahalanobis (équation 27).

En effet, à partir des équations (25), une région de validité d'une piste i à l'instant t est définie par :

$$\tilde{V}_i^t(\gamma) = \{Z_j(t); d_{ij}^2 \leq \gamma, d_{ij}^2 \text{ distance de Mahalanobis}\} \quad (28)$$

où γ est le seuil de la région de validité (« gate threshold »). On définit la probabilité P_G associée à la région de validité qui constitue la probabilité qu'une observation appartienne à la région de validité :

$$P_G = P\{Z(t) \in \tilde{V}_i^t(\gamma)\} \quad (29)$$

Le seuil γ est donc déterminé à partir d'un test du χ^2 à N_z degrés de liberté (où N_z est la dimension de la mesure Z).

Estimation d'état

Soit $Z(t)$ l'ensemble des observations validées à l'instant t (i.e. qui appartiennent à la région de validité) :

$$Z(t) = \{Z_l(t)\}_{l=1}^{m_t^i} \quad (30)$$

où m_t^i est le nombre d'observations considérées pour la mise à jour de l'état de la piste i à l'instant t .

On définit également l'ensemble de toutes les observations validées jusqu'à l'instant t pour la piste i par :

$$Z^{i,t} = \{Z(j)\}_{j=1}^t = \{Z^{i,t-1}, Z(t)\} \quad (31)$$

La densité de probabilité de l'état de la piste i connaissant l'ensemble $Z^{i,t-1}$ des mesures validées jusqu'à l'instant $t-1$ est supposée gaussienne, elle est définie par :

$$p(X(t) | Z^{i,t-1}) = N(X(t); \hat{X}_i(t | t-1), P_i(t | t-1)) \quad (32)$$

Soient les événements d'association (mutuellement exclusifs) suivants :

$$- \quad \theta_j(t) = \{ \text{la } j^{\text{ème}} \text{ observation validée } Z_j(t) \text{ est à l'origine de la piste à l'instant } t \} \quad (33)$$

avec $j = 1, \dots, m_t^i$;

$$- \quad \theta_0(t) = \{ \text{aucune des observations validées n'est à l'origine de la piste à l'instant } t \}. \quad (34)$$

La probabilité d'association entre une piste i et les observations validées $\theta_j(t)$ sachant $Z^{i,t}$ est définie par :

$$\alpha_{ij}(t) = P\{\theta_j(t) | Z^{i,t}\}, \quad j = 1, \dots, m_t^i \quad (35)$$

La somme de toutes les probabilités d'association doit être égale à **un** :

$$\sum_{j=0}^{m_t^i} \alpha_{ij}(t) = 1 \quad (36)$$

Comme précédemment, l'état estimé de la piste i à l'instant t est défini par l'espérance conditionnelle :

$$\begin{aligned}
\hat{X}_i(t|t) &= E(X_i(t|t)|Z^{i,t}) = \sum_{j=0}^{m_t^i} E(X_i(t|t)|\theta_j(t), Z^{i,t}) P\{\theta_j(t)|Z_i^t\} \\
&= \sum_{j=0}^{m_t^i} \hat{X}_{ij}(t|t) \alpha_{ij}(t)
\end{aligned} \tag{37}$$

$\hat{X}_{ij}(t|t)$ est la mise à jour de l'état de la piste i avec la $j^{\text{ème}}$ observation validée de l'événement $\theta_j(t)$. Elle est obtenue directement par l'équation de correction d'état du filtre de Kalman classique :

$$\hat{X}_{ij}(t|t) = \hat{X}_{ij}(t|t-1) + K_i(t) \tilde{Z}_{ij}(t), \quad j=1, \dots, m_t^i \tag{38}$$

où $K_i(t)$ est la matrice de gain de la piste i à l'instant t : $K_i(t) = P_i(t|t-1) H_t^T S_i^{-1}(t)$, $\tilde{Z}_{ij}(t)$ est le processus d'innovation entre la piste i et l'observation $Z_j(t)$ (équation 27).

Pour l'hypothèse $\theta_0(t)$ à l'instant t , le vecteur d'état de la piste i s'écrit par :

$$\hat{X}_{i0}(t|t) = \hat{X}_i(t|t-1) \tag{39}$$

L'équation de mise à jour de l'état associé à la piste i est obtenue en remplaçant les équations (38) et (39) dans l'équation (37) :

$$\hat{X}_i(t|t) = \hat{X}_i(t|t-1) + K_i(t) \tilde{Z}_i(t) \tag{40}$$

$$\text{où } \tilde{Z}_i(t) = \sum_{j=1}^{m_t^i} \alpha_{ij}(t) \tilde{Z}_{ij}(t) \tag{41}$$

Le processus d'innovation pondéré par les probabilités d'association $(\alpha_{ij}(t), j=1, \dots, m_t^i)$ entre la piste i et les m_t^i observations validées à l'instant t .

L'équation de la correction de la matrice de covariance d'erreur de l'état de la piste i est écrite par :

$$P_i(t|t) = \alpha_{i0}(t) P_i(t|t-1) + (1 - \alpha_{i0}(t)) P_i^c(t|t) + \tilde{P}_i(t) \tag{42}$$

$$\text{avec } \tilde{P}_i(t) = K_i(t) \left(\sum_{j=1}^{m_t^i} \alpha_{ij}(t) \tilde{Z}_{ij}(t) \tilde{Z}_{ij}^T(t) - \tilde{Z}_i(t) \tilde{Z}_i^T(t) \right) K_i^T(t) \tag{43}$$

$$\text{et } P_i^c(t|t) = (I - K_i(t) H_t(t)) P_i(t|t-1) \tag{44}$$

(P_i^c est la matrice de correction de la covariance d'erreur similaire à celle de filtre de Kalman classique et \tilde{P}_i est la matrice qui prend en compte l'effet des observations validées)

Si aucune observation n'a été considérée comme candidate pour la mise à jour de l'état de la piste i , alors la matrice de covariance d'erreur s'écrit :

$$P_i(t|t) = P_i(t|t-1)$$

Probabilités d'association

Comme on peut le constater, l'évaluation des probabilités d'association est une tâche essentielle pour l'algorithme PDA car elle permet de prendre en compte l'ensemble des mesures validées. Elles sont calculées de manière itérative et leur évaluation dépend de l'ensemble des observations jusqu'à l'instant courant. Cette probabilité peut s'écrire :

$$\alpha_{ij}(t) = P\{\theta_j(t) | Z^{i,t}\} = P\{\theta_j(t) | Z(t), m_t^i, Z^{i,t-1}\}, \quad j = 0, 1, \dots, m_t^i \quad (45)$$

Avec l'utilisation de la règle de Bayes, l'équation (47) peut s'écrire par :

$$\alpha_{ij}(t) = \frac{1}{c} p(Z(t) | \theta_j(t), m_t^i, Z^{i,t-1}) P\{\theta_j(t) | m_t^i, Z^{i,t-1}\}, \quad j = 0, 1, \dots, m_t^i \quad (46)$$

Où c est la constante de normalisation, elle est définie par :

$$c = \sum_j p(Z(t) | \theta_j(t), m_t^i, Z^{i,t-1}) P\{\theta_j(t) | m_t^i, Z^{i,t-1}\}$$

La densité de probabilité d'une observation validée j dans $\theta_j(t)$ pour une piste i et conditionnée par $Z^{i,t}$ est calculée par :

$$\begin{aligned} p(Z_j(t) | \theta_j(t), m_t^i, Z^{i,t}) &= P_G^{-1} N\left(Z_j(t); \hat{Z}_i(t|t-1), S_i(t)\right) = P_G^{-1} N\left(\tilde{Z}_{ij}(t); 0, S_i(t)\right) \\ &= P_G^{-1} |2\pi S_i(t)|^{1/2} \exp\left((-1/2) \tilde{Z}_{ij}^T(t) S_i^{-1}(t) \tilde{Z}_{ij}(t)\right) \end{aligned} \quad (47)$$

où P_G est la probabilité d'avoir une observation $Z_j(t)$ dans la région de validité \tilde{V}_i^t de la piste i à l'instant t (équation 29)

On montre [Bar-Shalom, 1988] que la densité de probabilité de l'équation (47) peut se réécrire :

$$p(Z(t) | \theta_j(t), m_t^i, Z^{i,t-1}) = \begin{cases} \left(V_i^t\right)^{-m_t^i+1} P_G^{-1} N\left(\tilde{Z}_{ij}(t); 0, S_i(t)\right), & j = 1, \dots, m_t^i \\ \left(V_i^t\right)^{-m_t^i}, & j = 0 \end{cases} \quad (48)$$

où V_i^t est le volume de \tilde{V}_i^t [Bar-Shalom, 1988], il est défini par :

$$V_i^t = c_{N_z} |\gamma S_i(t)|^{1/2} = c_{N_z} \gamma^{N_z/2} |S_i(t)|^{1/2} \quad (49)$$

avec N_z la dimension de l'espace ;

$c_{N_z} = \pi^{N_z/2} / \Gamma\left(\frac{N_z}{2} + 1\right)$ (avec $c_1 = 2, c_2 = \pi, c_3 = 4\pi/3$, etc...), le volume de la sphère unité de dimension N_z .

La densité spatiale λ_i des fausses alarmes dans une région de validité d'une piste i est calculée, en utilisant un modèle non paramétrique de PDA et on remplace le paramètre de Poisson par la densité spatiale d'échantillon de mesures validées [Bar-Shalom, 1988]. Cette densité s'écrit :

$$\lambda_i = \frac{m_t^i}{V_i^t} \quad (50)$$

A partir des équations (29), (47) et (49), on déduit [Bar-Shalom, 1988] les équations qui permettent de calculer les probabilités conditionnelles, en connaissant l'ensemble des mesures validées jusqu'à l'instant t par :

$$\alpha_{ij}(t) = \frac{e_{ij}}{b + \sum_{l=1}^{m_t^i} e_{il}}, \text{ avec } j=1, \dots, m_t^i \quad (51)$$

et $\alpha_{i0}(t) = \frac{b}{b + \sum_{l=1}^{m_t^i} e_{il}}, \text{ avec } j=0 \quad (52)$

Avec pour un modèle paramétrique :

$$b = \lambda_i |2\pi S_i(t)|^{1/2} (1 - P_d P_G) / P_d$$

où $e_{ij}(t) = \exp\{(-1/2) \tilde{Z}_{ij}^T(t) S_i^{-1}(t) \tilde{Z}_{ij}(t)\}.$

I.4.3 Méthode d'association de données multi-objets

I.4.3.1 Méthode des hypothèses multiples (MHT)

Dans le contexte de suivi multi-objets, la phase d'association observations-piste joue un rôle non négligeable dans l'apparition des trajectoires des objets (ou pistes). La méthode MHT traite de l'association de séquences d'observations et de l'évaluation de la probabilité de chaque séquence [Bar-Shalom, 1988]. Avec cette méthode, il est facile de démarrer des nouvelles pistes avec les observations qui n'ont pas été associées.

Cette méthode a été initiée par [Reid, 1979] pour le suivi d'objets multiples dans un environnement encombré. Le principe de cette méthode réside dans la génération d'hypothèses pour chaque nouvelle observation. L'objectif est de garder les hypothèses les plus probables. La densité de probabilité de chaque hypothèse d'association est supposée gaussienne. L'évaluation dépend de trois paramètres : la probabilité d'association entre la piste et la nouvelle observation associée, le vecteur d'état et la matrice de covariance de l'erreur de la piste.

Pour chaque nouvelle observation, il y a trois cas possibles :

- c'est une fausse alarme ;
- elle appartient à une piste déjà existante ;
- il s'agit d'une nouvelle piste.

La croissance des hypothèses d'association suit une structure en arbre [Blackman, 1986], dans lequel chaque segment (tronçon entre deux nœuds de l'arbre, pour une période d'échantillonnage) représente une hypothèse de présence de piste et sa position à l'instant courant. Pour chaque observation, au moins deux nœuds de l'arbre sont construits.

Il est clair que dans ce contexte, le nombre d'hypothèses croît de manière exponentielle au cours du temps. On peut donc appliquer différentes techniques afin de :

- regrouper les hypothèses pour réduire la complexité algorithmique.
- éliminer les hypothèses de faible probabilité.

Différentes techniques de réduction d'hypothèses peuvent être appliquées [Bar-Shalom, 1988] dont une des plus populaires est le JPDA.

Le concept de regroupement des hypothèses a été introduit par [Reid, 1979]. Cette méthode réduit le nombre des probabilités à calculer et traite séparément les hypothèses qui n'ont pas d'interaction dans le groupe.

On trouvera dans [Blackman, 1986][Bar-Shalom, 1988] une description détaillée de l'algorithme MHT.

I.4.3.2 Méthode d'association probabiliste conjointe de données (JPDA)

Dans la méthode PDA, l'association est faite entre une unique piste et toutes les observations disponibles à l'instant courant, c'est le cas mono-objet. En revanche, une extension de la méthode PDA détaillée précédemment a été développée afin de traiter le cas multi-objet, c'est la méthode JPDA. Cette dernière méthode est aussi un cas particulier de la méthode MHT qui permet de minimiser le coût de construction et le calcul des probabilités des hypothèses d'association.

La méthode JPDA traite le cas de chevauchement qui se produit entre différentes régions de validité des pistes et pour lesquelles des observations peuvent être associées simultanément à plusieurs pistes. Pour cette méthode, toutes les hypothèses d'association envisageables sont étudiées et une probabilité est attachée à chaque hypothèse construite. Le cas des observations correspondant à des fausses alarmes est également considéré par cette méthode.

L'inconvénient de cette méthode est la croissance exponentielle du nombre d'hypothèses dans le cas où il y a des observations appartenant à plusieurs pistes. La création des nouvelles pistes par cette méthode est ainsi difficile.

Principe de la méthode

Le principe de cette méthode est le suivant :

- une prédiction des états de toutes les pistes antérieurement existantes $\hat{X}(t|t-1) = (\hat{X}_1(t|t-1), \dots, \hat{X}_{n_{t-1}}(t|t-1))$. Cette étape prépare les états de l'instant $t-1$ pour la réception des prochaines observations du système de perception à l'instant t $Z(t) = (Z_1(t), \dots, Z_{m_t}(t))$ (figure 14);
- une affectation des observations à chacune des pistes à partir de leurs régions de validité (identique au paragraphe I.4.2.2).
- un regroupement des pistes qui ont des observations communes, c'est-à-dire des observations appartenant aux régions de validité de plus qu'une piste. Si on prend l'exemple de la figure 14, les pistes prédites $(\hat{X}_1(t|t-1), \hat{X}_2(t|t-1))$ font partie d'un seul groupe, ainsi que piste prédite $\hat{X}_3(t|t-1)$ fait partie d'un autre groupe. Par contre, l'observation $Z_2(t)$ qui

n'appartient pas à aucune des régions de validité des pistes sera, peut être, à l'origine de la création d'une nouvelle piste.

- La construction des toutes les hypothèses possibles d'association pour chacun des groupes des pistes. Pour chaque piste les deux hypothèses des équations (33) et (34) sont appliquées sur ses observations associées. Chaque hypothèse est construite selon la règle suivante : une observation ne peut être à l'origine que d'une seule piste et réciproquement une piste est associée à une unique observation, excepté l'hypothèse de l'équation (34).
- la probabilité de chaque hypothèse est obtenue par multiplication des probabilités d'association qui font l'hypothèse. Ensuite, la probabilité d'association pour une piste est obtenue par l'addition de probabilités de toutes les hypothèses auxquelles elle appartient. Comme précédemment, cette probabilité est intégrée dans les équations de mise à jour de l'état de la piste.

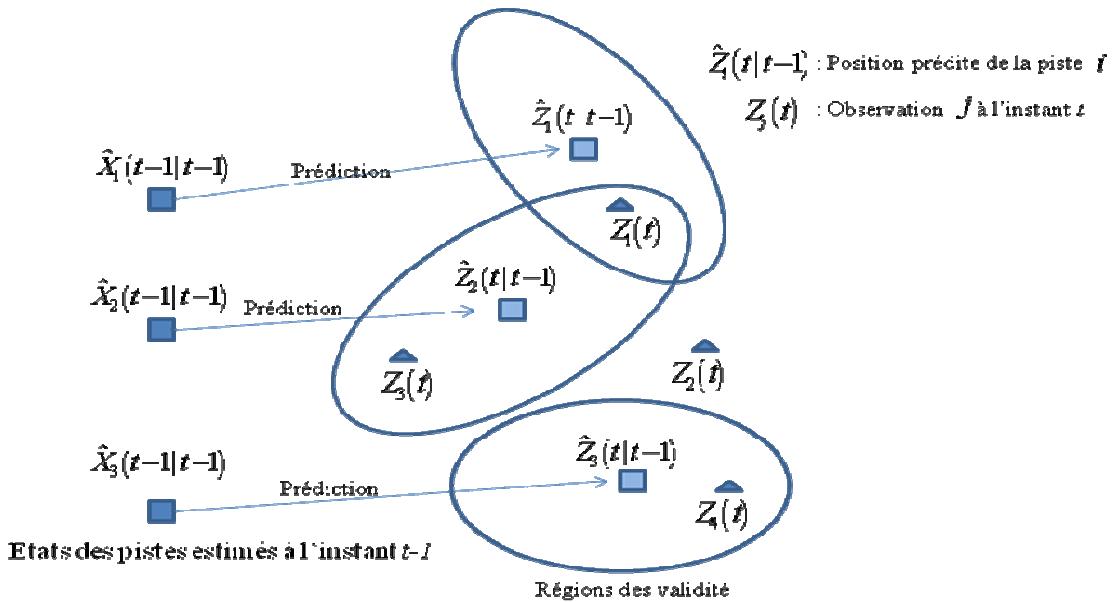


Figure 14: Principe de la méthode JPDA.

Estimation d'état

Le point central de cette approche réside dans le calcul des probabilités d'association à un instant t pour les événements conjoints suivants :

$$\Psi(t) = \bigcap_{j=1}^{m_t} \psi_{j_{i_j}}(t) \quad (53)$$

où $\psi_{j_{i_j}}(t) = \{Z_j(t) \text{ la } j^{\text{ème}} \text{ observation validée est à l'origine de la piste } i\}$ (54)

avec $j = 1, \dots, m_t$; $i = 0, 1, \dots, n_{t-1}$

i_j est l'indice de la piste i à laquelle l'observation j est associée, $0 \leq i_j \leq n_t$.

Notons que la matrice de validation qui représente les associations des observations disponibles à l'instant courant t aux pistes antérieurement existantes et qui font partie d'un même ensemble est définie par :

$$\Omega = (\omega_{j_i}), \quad j = 1, \dots, m_t; \quad i = 0, 1, \dots, n_{t-1} \quad (55)$$

$$\text{avec } \omega_{ij} = \begin{cases} 1 & \text{si } d_{ij}^2 \leq \gamma \\ 0 & \text{sinon} \end{cases} \text{ (voir paragraphe I.4.2.2)}$$

Dans ce cas, $i=0$ signifie « aucune piste ». Les composantes de la colonne correspondante dans la matrice Ω sont toutes à 1. Ceci signifie que chaque mesure peut être une fausse alarme. Reprenant l'exemple de la figure 14, la matrice de validation correspondante aux mesures validées pour les pistes prédites $(\hat{X}_1(t|t-1), \hat{X}_2(t|t-1), \hat{X}_3(t|t-1))$ est décrite par :

$$\Omega = \left(\begin{array}{c|cccc} & & & & i \\ \hline 0 & 1 & 2 & 3 & \\ \hline 1 & 1 & 0 & 0 & 1 \\ 1 & 0 & 0 & 0 & 2 \\ 1 & 0 & 1 & 0 & 3 \\ 1 & 0 & 0 & 1 & 4 \end{array} \right) \left. \right\} j \quad (56)$$

Chaque événement de $\Psi(t)$ peut être représenté de manière matricielle par :

$$\hat{\Omega}(\Psi) = (\hat{\omega}_{ji}(\Psi)) \quad (57)$$

$$\text{avec } \hat{\omega}_{ji}(\Psi) = \begin{cases} 1 & \text{si } \psi_{ji} \in \Psi \\ 0 & \text{sinon} \end{cases} \quad (58)$$

Les événements réalisables sont les événements conjoints dans lesquels une mesure au maximum est à l'origine d'une piste [Fortmann, 1983]. Ceci signifie que $\forall \underbrace{j \neq k}_{\text{Indice observations}} \text{ et } i_j > 0 \rightarrow i_j \neq i_k$.

La matrice (58) est construite à partir des événements réalisables dans la matrice (56) en utilisant les règles suivantes :

- Une observation est associée à une seule piste, c'est-à-dire :

$$\sum_{i=0}^{n_t} \hat{\omega}_{ji}(\Psi) = 1, \quad j = 1, \dots, m_t \quad (59)$$

- Une seule observation au maximum est à l'origine d'une piste, c'est-à-dire :

$$\delta_i(\Psi) = \sum_{j=1}^{m_t} \hat{\omega}_{ji}(\Psi) \leq 1, \quad i = 1, \dots, n_t \quad (60)$$

$$\text{avec } \delta_i(\Psi) = \begin{cases} 1 & \text{si } i_j = i \text{ pour certains } j \\ 0 & \text{si } i_j \neq i \ \forall j \end{cases} \text{ qui indique si l'observation } Z_j(t) \text{ a été associée}$$

à une des pistes antérieurement existantes dans Ψ . Si l'association s'est produite, alors ça signifie que la piste est détectée à cet instant.

On définit un indicateur qui permet de signaler l'association d'une observation $Z_j(t)$ à une telle piste :

$$\tau_j(\Psi) = \sum_{i=1}^{n_t} \hat{\omega}_{ji}(\Psi), \quad j = 1, \dots, m_t \quad (61)$$

$$\text{où } \tau_j(\Psi) = \begin{cases} 1 & \text{si } i_j > 0 \\ 0 & \text{si } i_j = 0 \end{cases}$$

A partir de l'équation (61), le nombre des fausses alarmes dans Ψ est calculé par:

$$\phi(\Psi) = \sum_{j=1}^{m_t} [1 - \tau_j(\Psi)] \quad (62)$$

Probabilités conjointe d'association de données

Avec l'utilisation de la règle de Bayes, la probabilité conjointe d'association $\Psi(t)$ conditionnée par toutes les observations jusqu'à l'instant t est définie par:

$$\begin{aligned} P\{\Psi(t) | Z^t\} &= P\{\Psi(t) | Z(t), Z^{t-1}\} \\ &= \frac{1}{c} p(Z(t) | \Psi(t), Z^{t-1}) P\{\Psi(t) | Z^{t-1}\} \\ &= \frac{1}{c} p(Z(t) | \Psi(t), Z^{t-1}) P\{\Psi(t)\} \end{aligned} \quad (63)$$

où c est la constante de normalisation.

Toutes les régions de validité des pistes d'un cluster participent maintenant à la région entière de surveillance, ce qui donne une $P_G = 1$.

Le premier facteur de l'équation (63) représente la densité conjointe des probabilités des m_t observations validées pour un cluster, conditionnée par $\Psi(t)$. Elle est définie par :

$$p(Z(t) | \Psi(t), Z^{t-1}) = \prod_{j=1}^{m_t} p(Z_j(t) | \psi_{ji}(t), Z^{t-1}) \quad (64)$$

La densité de probabilité d'une observation $Z_j(t)$ est définie par :

$$p(Z_j(t) | \psi_{ji}(t), Z^{t-1}) = \begin{cases} N_i(\tilde{Z}_{ij}(t); 0, S_i) & \text{si } \tau_j(\Psi(t)) = 1 \\ V^{-1} & \text{si } \tau_j(\Psi(t)) = 0 \end{cases} \quad (65)$$

Une observation de type clutter a une densité uniforme de valeur V^{-1} , où V est le volume de la région de validité.

Comme précédemment, on suppose que la densité de probabilité d'une observation $Z_j(t)$ associée à la piste i_j est gaussienne. Elle est définie par :

$$N_i(\tilde{Z}_i(t); 0, S_i(t)) = \exp\left(\left(-\frac{1}{2}\right) \tilde{Z}_{ij}^T(t) S_i^{-1}(t) \tilde{Z}_{ij}(t)\right) / (2\pi)^{N_z/2} |S_i|^{1/2} \quad (66)$$

où N_z est la dimension de l'espace.

En remplaçant l'équation (66) dans l'équation (65), on obtient :

$$p(Z(t) | \Psi(t), Z^{t-1}) = V^{-\phi(\Psi)} \prod_{j=1}^{m_t} \left(N_i(\tilde{Z}_{ij}(t); 0, S_i(t)) \right)^{\tau_j(\Psi)} \quad (67)$$

Le nombre d'hypothèses dans lesquelles le même ensemble des pistes a été détecté est obtenu par la fonction de permutation suivante [Fortmann, 1983] :

$$P_{m_t - \phi(\Psi)}^{m_t} = \frac{m_t!}{\phi(\Psi)!} \quad (68)$$

où m_t est le nombre des observations disponibles à l'instant t et

$m_t - \phi(\Psi)$ est le nombre de pistes détectées à l'instant t .

Avec l'équation (68), le second facteur de l'équation (63) s'écrit :

$$P\{\Psi(t)\} = \frac{\phi!}{m_t!} \prod_{i:\delta_i=1} P_d^i \prod_{i:\delta_i=0} (1-P_d^i) \frac{e^{-CV} (CV)^\phi}{\phi!} \quad (69)$$

En remplaçant les équations (67) et (69) dans (63), l'équation (63) devient:

$$\begin{aligned} P\{\Psi(t) | Z'\} &= \frac{1}{c} \frac{\phi!}{m_t!} V^{-\phi} \prod_{j:\tau_j=1} \left(N_i(\tilde{Z}_{ij}(t); 0, S_i(t)) \right)^{\tau_j} \\ &\quad \cdot \prod_{i:\delta_i=1} P_d^i \prod_{i:\delta_i=0} (1-P_d^i) \frac{e^{-CV} (CV)^\phi}{\phi!} \end{aligned} \quad (70)$$

Après la suppression de quelques facteurs qui apparaissent dans le numérateur et le dénominateur [Fortmann, 1983], l'équation (70) devient :

$$\begin{aligned} P\{\Psi(t) | Z'\} &= \frac{C^\phi}{c} \prod_{j:\tau_j=1} \left(N_i(\tilde{Z}_{ij}(t); 0, S_i(t)) \right)^{\tau_j} \\ &\quad \cdot \prod_{i:\delta_i=1} P_d^i \prod_{i:\delta_i=0} (1-P_d^i) \end{aligned} \quad (71)$$

où c est la constante de normalisation.

Probabilités d'association de données

La probabilité d'association α_{ij} entre la piste i et l'observation associée $Z_j(t)$ est obtenue en additionnant la probabilité de toutes les hypothèses dans lesquelles cette condition est produite :

$$\begin{aligned} \alpha_{ij} &= P\{\psi_{ji} | Z'\} = \sum_{\Psi} P\{\Psi | Z'\} \hat{\omega}_{ji}(\Psi), \\ j &= 1, \dots, m_t, \quad i = 0, 1, \dots, n_t \\ \alpha_{i0} &= 1 - \sum_{j=1}^{m_t} \alpha_{ij}, \quad i = 0, 1, \dots, n_t \end{aligned} \quad (72)$$

Une fois que le calcul des probabilités d'association liées au JPDA est réalisé, l'estimation de l'état de chaque piste demeure identique au PDA.

I.5 Capteurs actifs

I.5.1 Introduction

Les systèmes de perception de l'environnement nécessitent l'usage de capteurs de détection extéroceptifs et proprioceptifs. Les capteurs extéroceptifs donneront des informations sur l'environnement externe au système de perception, les capteurs proprioceptifs fourniront des informations sur des états internes au système. Ainsi, un capteur de vitesse est un capteur proprioceptif d'un système de détection d'obstacle embarqué dans un véhicule et un capteur image de détection d'obstacles est un capteur extéroceptif de ce véhicule. Ces capteurs extéroceptifs et proprioceptifs peuvent être actifs ou passifs. On parle de capteur actif lorsque l'information reçue par le capteur l'est en retour d'un signal émis. Un capteur est dit passif lorsqu'il reçoit une énergie sans pour autant émettre de signal.

Des exemples de capteurs extéroceptifs actifs sont

- les Lidar (*Light Detection And Ranging*) ou capteur « Laser scanner » (Laser –*Light Amplification by Stimulated Emission of Radiation*, pour la détection d'objets à l'aide d'une lumière laser,
- les sonars (*SOund Navigation And Ranging*) pour la détection d'objet dans l'eau à l'aide d'ondes sonores ou encore
- les Radar (*RAdio Detection And Ranging*) pour détecter et déterminer la distance et/ou la vitesse d'objets à l'aide d'ondes radio.

Des exemples de capteurs extéroceptifs passifs sont :

- les capteurs optiques de type vidéo caméra.

De façon générale, un capteur est caractérisé par ses contraintes d'utilisation et ses performances.

- pour quel objectif a-t-il été conçu : quel type d'événement détecte-t-il, quelle est sa nature (distance, volume, pression, température...) ?
- pour/dans quel environnement est-il amené à fonctionner (espace, eau, terre, en intérieur ou en extérieur, en environnement libre ou contraint, embarqué ou non, utilisation sur support statique ou mobile...) ?
- quelles sont les caractéristiques de sa grandeur physique (mesures, variation de la grandeur, sensibilité, précision, temps de réponse, bande passante, résolution...) ?

Avec l'arrivée des capteurs intelligents dans les années 80, d'autres fonctionnalités ont été ajoutées aux capteurs telles que des fonctions d'auto-test, de configuration de traitement, d'étalonnage, d'interconnexion à des bus de terrain...

I.5.2 La technologie laser

I.5.2.1 Domaines d'utilisation du laser

La technologie laser est utilisée dans de nombreuses applications. On peut citer son utilisation dans des applications industrielles (découpe, perçage, soudage, marquage et gravure, traitement de surface...) et des applications de mesure et métrologie pour [LAS_URL] :

- la mesure en continu des mouvements durant des expériences de modélisation (interférométrie) ;
- la transmission de données avec une portée de 2 à 5000 mètres et des débits de 200 kb/s à 155 Mb/s ;
- la mesure de la vitesse locale d'un écoulement aérodynamique (vélocimétrie) ;
- l'analyse de la taille de particules allant de 0,02 μm à 2000 μm (granulométrie) ;
- la mesure sans contact, de 10 cm à quelques km, sur le principe de la mesure du temps de propagation de la lumière en fonction de la distance (télémétrie).

Le paragraphe suivant explique le principe de la télémétrie laser utilisée par les capteurs de détection pour la surveillance et l'automobile.

I.5.2.2 Principe des télémètres lasers utilisés pour la surveillance et l'automobile

Le fonctionnement des télémètres lasers est basé sur le principe du temps de vol (figure 15). La différence de temps entre le moment de l'émission du tir laser et l'instant de la détection du signal de réception en retour est mesuré. Ce temps, appelé « temps de vol », correspond au temps mis par la lumière pour réaliser la distance aller-retour entre l'émetteur laser et le récepteur en passant par la cible illuminée qui réfléchit le signal. Il sert alors au calcul de la distance entre le télémètre et la cible et de son incertitude sur la distance :

$$D = \frac{1}{2} \times C \times (T_{\text{Signal_Fin_Mesure}} - T_{\text{Signal_Début_Mesure}}) \text{ et } \frac{\Delta D}{D} = \frac{1}{2} \times \left(\frac{\Delta C}{C} + \frac{\Delta t}{t} \right),$$

où D est la distance du capteur à la cible, C est la vitesse de la lumière, $T_{\text{Signal_Fin_Mesure}}$ et $T_{\text{Signal_Début_Mesure}}$ les temps respectivement de début/fin du signal émis/reçu mesurés lorsque le signal atteint un certain seuil, $\frac{\Delta D}{D}$ l'incertitude sur la mesure de la distance qui dépend de celle de la mesure du temps $\frac{\Delta t}{t}$, $\frac{\Delta C}{C}$ l'incertitude sur la vitesse de propagation de la lumière.

La précision de la mesure est d'après [Besesty, 1999] donnée par l'écart type :

$$\sigma_d = \frac{t_{\text{montée_impulsion}}}{2,36 \times \text{SNR}},$$

où $t_{\text{montée_impulsion}}$ est le temps de montée de l'impulsion et SNR (« Signal Noise Ratio ») le rapport signal sur bruit qui dépend de la distance du télémètre à la cible.

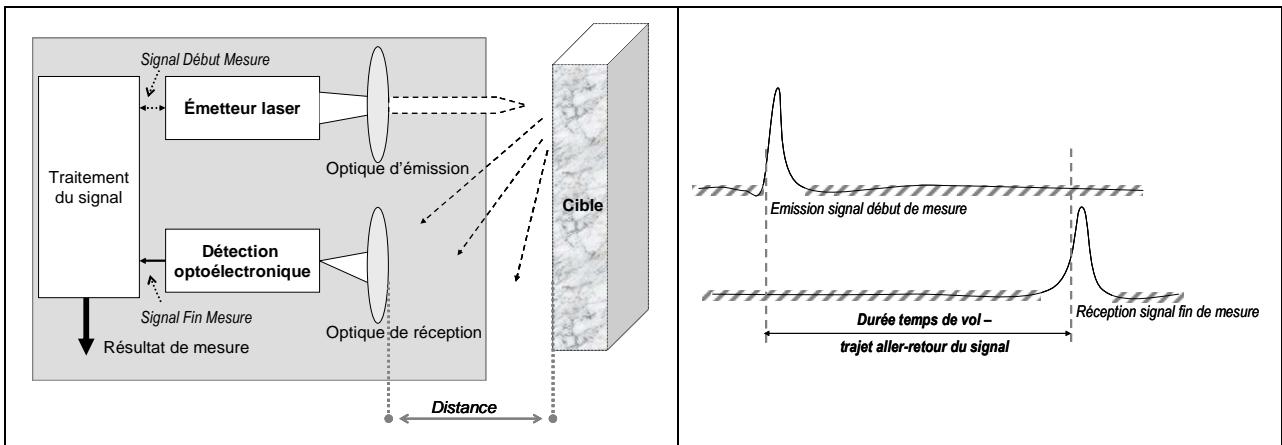


Figure 15 : Principe d'un télémètre laser à temps de vol [Besesty, 1999].

Outre la précision de la mesure représentée par l'incertitude sur la mesure, les caractéristiques importantes d'un tel capteur pour une utilisation en embarqué dans une automobile sont :

- sa portée,
- son ouverture angulaire horizontale et verticale (robustesse au tangage),
- sa sensibilité, c'est à dire sa capacité à pouvoir détecter les obstacles, dans notre cas notamment dans différents environnements climatiques (une des difficultés des technologies radar est la vision par temps de pluie, brouillard),
- sa fiabilité, à savoir sa capacité à délivrer une même information de façon répétitive (malgré les phénomènes de roulis, tangage et lacet).

Les données réelles utilisées dans le cadre de cette thèse proviennent de capteurs lasers rotatifs des sociétés SICK et IBEO :

- la société SICK fournit des capteurs industriels optiques et de proximité, des capteurs pour les systèmes de sécurité, l'environnement, l'identification automatique et la mesure laser pour des domaines d'application aussi variés que l'industrie automobile, la construction de machines, l'énergie, l'industrie chimique, l'industrie électrique, l'environnement, la logistique, le contrôle du trafic, les transports [SICK_URL]. Créé en 1946, Sick a ouvert son marché vers les lasers scanners à temps de vol en 1994. En 2000, avec l'acquisition d'IBEO Lasertechnik Hipp KG, elle intègre à sa gamme les télémètres laser d'IBEO.
- de son côté, en devenant filiale de SICK à part entière, la société IBEO [IBEO_URL], créée en 1998 et située à Hamburg en Allemagne, devient IBEO Automobile Sensor. Elle resserre son activité sur les Lasers Scanner pour l'automobile et bénéficie du savoir faire de Sick pour l'intégration de ses capteurs.

Nous présentons ci-après, au travers de l'évolution des capteurs d'IBEO, société qui a participé avec l'INRETS au projet européen 5^{ème} PCRD CARSENSE de 2000 à 2003 sur la détection d'obstacles automobile multi-capteurs, l'évolution des capteurs laser automobile de détection d'obstacles.

I.5.3 Evolution des capteurs laser automobile de détection d'obstacle

L'inconvénient majeur des capteurs de type télémètre laser pour une application en embarqué sur un véhicule pour une détection d'obstacle en situation de conduite sur route ou autoroute est leur trop grande directivité. Celle-ci a pour conséquence le décrochage régulier de l'obstacle suivi parce que

d'une part celui-ci entre et sort régulièrement de la ligne de tir et d'autre part la ligne de tir du signal lui-même change d'inclinaison en raison notamment des phénomènes de tangage auxquels est soumis le véhicule équipé du capteur (passage de l'horizontalité à une inclinaison en direction du sol ou du ciel).

Pour pallier la première raison du décrochage de l'obstacle, un mouvement de balayage ou de rotation du tir laser a été ajouté afin d'élargir la surface de détection du capteur en lui apportant une ouverture angulaire. Les mécanismes de balayage n'étant pas robustes aux vibrations, c'est l'utilisation de moteurs rotatifs qui a été finalement retenu pour réaliser ce balayage de la scène à surveiller.

Pour pallier la perte du signal en raison des vibrations du véhicule, la société IBEO a conçu dans les années 2000-2002 [Fuerstenberg, 2002a][Fuerstenberg, 2002b], sur la base d'une première expérience (capteur laserscanner IBEO LD), un capteur rotatif multi-couche, « l'IBEO LDML Automotive laserscanner » (LDML –LadarDigital MultiLayer). Pour chaque angle de tir, une mesure d'obstacles ne se fait plus par un tir dans une direction mais par quatre tirs définis les uns aux autres avec une déviation angulaire de $0,8^\circ$, créant ainsi une ouverture angulaire verticale de $3,2^\circ$.

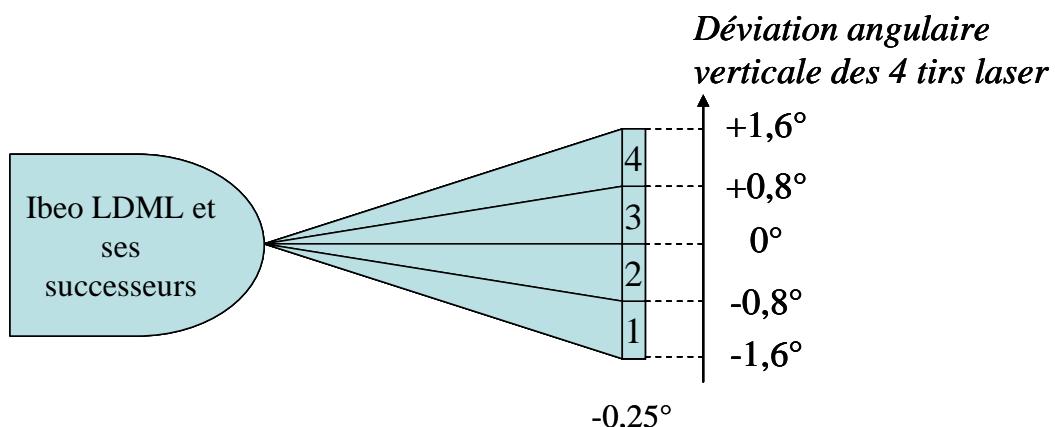


Figure 16 : Ouverture angulaire verticale de l'IBEO LDML palliant les pertes dues au tangage [IBEO_URL].

Un autre souci des capteurs laser sont ses pauvres performances en temps de pluie, la pluie réfléchissant les tirs lasers. Ceci a été également résolu pour le capteur IBEO LDML qui attend pour chaque tir laser le retour du second écho [Fuerstenberg, 2002a][Fuerstenberg, 2002b]. Ainsi, à chaque impulsion laser, deux mesures de réflexion sont réalisés, ce qui donne huit mesures de réflexion en comptant les quatre tirs laser pour chaque échantillonnage d'une rotation du capteur. L'ALASCA[®] (« Automotive LASer SCanner ») a alors succédé à l'IBEO LDML. La version suivante, ALASCA[®] XT [Fuerstenberg, 2006], ainsi que la version produite en série, totalement embarquable (dimension H85cmxL128cmxP83cm pour un poids de 900g avec les traitements intégrés au module) et commercialisée en automne 2008 (IBEO LUX laser scanner), comptent jusqu'à trois mesures de réflexion par impulsion laser.

L'apport de l'ALASCA[®], successeur de l'IBEO LDML, a été de déterminer quelles mesures du capteur proviennent d'un signal retourné par un réflecteur (tel qu'une plaque numérologique et les phares arrières d'un véhicule, les panneaux signalétiques...) d'une autre surface à moindre pouvoir

réfléchissant afin d'améliorer le pistage d'objet et la classification [Fuerstenberg, 2004]. Ceci est possible car la réflexion totale ou diffuse d'un objet crée des différences dans le rayonnement de l'impulsion de l'écho au niveau du récepteur du capteur qui peuvent être mesurée en tenant compte de celles qui proviennent de la distance et de l'angle d'incidence de la cible [Fuerstenberg, 2004].

Ces derniers capteurs ont également été modifiés pour permettre une détection de ligne. On retrouve ici l'idée d'un tir oblique vers le sol, tel que cela avait été imaginé en 1992 dans le cadre du programme de recherche de détection d'obstacles automobile PROMETHEUS PROCHIP France avec le capteur laser IR développé par le LAAS du CNRS [Estève, 1995], capteur qui déjà était rotatif. Dans ce cas là cependant, il n'y a pas de diode laser supplémentaire. Deux plans de balayages additionnels dirigés vers le sol ont été ajoutés, aux quatre autres plans de balayage dédiés à la détection d'obstacles, à l'aide de deux miroirs disposés de part et d'autre d'un capteur ALASCA®. Ces miroirs réfléchissent et renvoient vers la route les impulsions lasers qui subissent l'occlusion du pare-choc du véhicule dans lequel le capteur est intégré [Dietmayer, 2005] [Kibbel, 2005]. [Dietmayer, 2005] fait état de deux plans supplémentaires dirigés vers la surface du sol dont les impacts sont à environ 5 m et 15 m. Dans [Kibbel, 2005], l'arrangement des miroirs donne une zone de tir vers le sol d'environ 3,5 à 4,5 mètres dans la direction de la conduite et à ± 3 mètres dans la direction latérale du véhicule pour une détection des marquages à gauche et à droite du véhicule.

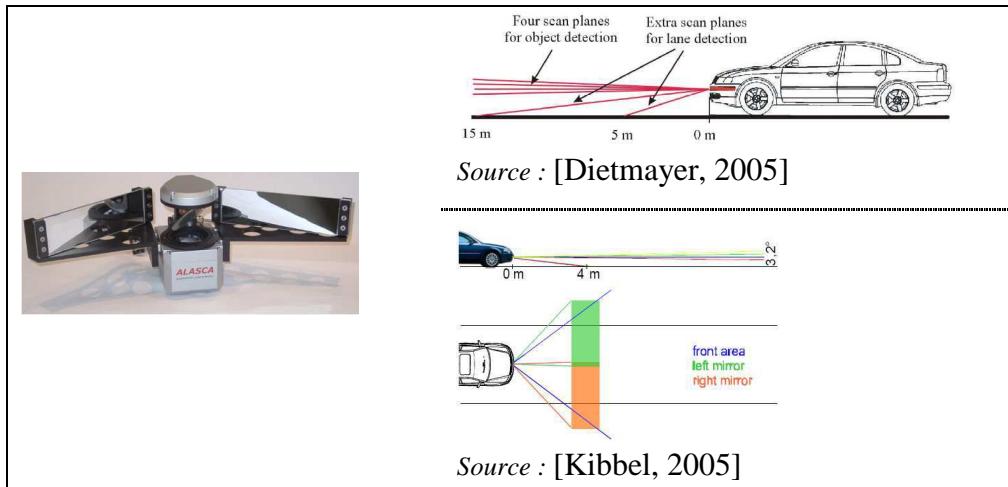


Figure 17 : Prototype de test de l'ALASCA® avec 2 miroirs pour la détection de ligne d'après [Dietmayer, 2005] et [Kibbel, 2005].

En plus des modifications physiques de ces capteurs, d'importantes recherches algorithmiques ont été faites au travers de collaboration avec l'université d'Ulm (Allemagne) et à l'occasion de projets européens du 5^{ème} PCRD et du programme de recherche PReVENT 6^{ème} PCRD. Ces algorithmes sont notamment des traitements de segmentation des échos (ρ, θ) (données brutes) délivrés à chaque rotation, de compensation du mouvement propre du véhicule pour améliorer l'association de l'algorithme de suivi d'objet, de classification d'objets, de détection de ligne. A titre d'exemple, nous listons ci-après les traitements développés pour les capteurs IBEO LDML dont nous disposons un exemplaire à l'INRETS [Deram, 2007].

Le capteur LDML (Multi-Layer Laser-baseD) a été conçu pour supporter une large gamme d'application automobile, notamment le freinage d'urgence, le « Stop & Go », la reconnaissance de piéton et le « Pre-Crash » [Fuerstenberg, 2002b]. C'est un laser multifaisceaux à balayage qui

dispose de quatre plans horizontaux de faisceaux séparés de $0,8^\circ$. L'ouverture angulaire de la scène balayée ainsi que son orientation (angle de début et de fin) sont deux paramètres qui peuvent être configurés par l'utilisateur.

L'architecture et les développements algorithmiques développés par IBEO ont été les suivants :

architecture matérielle [Fuerstenberg, 2002b] :

- connexion du capteur à une unité centrale de type PC industriel qui exécute sur les données brutes les algorithmes de détection et suivi d'objets et les fonctions de classification d'objets et de détection de rue.
- une station hôte connectée à l'unité centrale via un bus CAN reçoit les données résultantes qui peuvent être réutilisées : données « objet », information sur rue.
- les données de type échos, en sortie des interfaces Ethernet ou Arcnet de l'unité centrale) sont visualisables sur la station hôte via le logiciel de la société IBEO ASD Birdview.

architecture logicielle : [Fuerstenberg, 2002a] [Fuerstenberg, 2002b] utilise quatre modèles comportant des interdépendances pour la détection et la modélisation du trafic dynamique. Ces modèles sont :

- le modèle capteur comprenant la connaissance du capteur, la segmentation de base et la segmentation avancée,
- le modèle véhicule comprenant la connaissance du véhicule et les paramètres du véhicule ;
- le modèle objet comprenant la connaissance des objets, la détection d'objet, le suivi d'objet, la classification d'objet et la gestion d'objet ;
- le modèle route comprenant la connaissance des routes, la classification du type de route, la dynamique de la route et la détection de ligne.

les développements testés par IBEO :

[Fuerstenberg, 2003b] présente les algorithmes de traitement pour la détection de piétons et la classification et [Fuerstenberg, 2003a] ceux pour la détection de ligne. De plus, on trouvera dans [Fuerstenberg, 2003c] une description du modèle d'état choisi, les différentes approches testées en simulation pour l'association des « segments » aux objets (approches centre de gravité, boîte rectangulaire, en particulier pour la détection de véhicule, et approche deux lignes) et, enfin, des résultats sur la reconnaissance de piétons. D'après ces références, les différents traitements réalisés sont dans l'ordre d'exécution les suivants :

1. *Segmentation des données brutes* obtenues après une rotation du miroir : une boîte rectangulaire est créée autour des mesures qui est définie par sa longueur, sa largeur, son centre géométrique et de gravité.
2. *Estimation du mouvement absolu du véhicule* lorsque les informations inertielles (angle de braquage et la vitesse des roues) sont disponibles [Fuerstenberg, 2003a] et *compensation avant association du mouvement propre du véhicule* sur les objets segmentés [Fuerstenberg, 2003a].
3. *Suivi d'objet* : une comparaison des paramètres des segments obtenus à l'étape 1 avec les paramètres prédicts des objets précédemment connus est réalisée, suivie d'une étape d'association/création de pistes. Pour ce suivi d'objet, des algorithmes tels que le plus proche voisin et le plus proche voisin global ont été évalués, un filtre de Kalman est utilisé.
4. *Classification d'objets* : elle est basée sur la connaissance a priori des contours d'objet des utilisateurs classiques de la route, à savoir les voitures, les camions/bus, les

motocyclettes/bicyclettes et les piétons. Elle prend en compte les précédentes classifications des objets et leur dynamique [Fuerstenberg, 2002a]. Un modèle environnemental est utilisé en cas de disponibilité d'une détection du type de route.

5. *Détection de ligne* : une détermination de la largeur, de la position et de la courbe de la route est réalisée, ainsi qu'une classification du type de route à partir de la valeur moyenne de la route ; la détection du type de route peut aider à l'étape 4 en donnant une information sur les types d'utilisateurs attendus [Fuerstenberg, 2003a].

I.5.4 Présentations des capteurs Sick et IBEO utilisés et de leurs données

Les données du capteur LDML disponible à l'INRETS n'ont pu être utilisées. En effet, les seules données récupérables de ce capteur sont les données objets en sortie du module qui exécute leur algorithme de détection d'objet, de suivi et de classification. Nous ne sommes pas parvenus à accéder aux données échos des quatre tirs laser pour lesquels nous n'avons ni le format de transmission dans les trames Ethernet ou Arcnet, ni le format d'enregistrement par les logiciels propriétaires d'IBEO. Notons que la version éducation de son successeur, le capteur ALASCA, est allégée des options de traitement et est fournie avec des librairies de développement qui permettraient d'avoir accès à ses échos.

En l'état actuel, nous n'avons donc pu bénéficier de ces données pour le développement de nos algorithmes. Par contre, l'école des Mines et la société RTMaps nous ont transmis des enregistrements sur route des données brutes (ρ, θ) du capteur IBEO LD. Nous avons également travaillé sur les enregistrements qui nous ont été fournis par l'UTC de Compiègne avec le capteur SICK LMS 200. Nous présentons ci après chacun de ces deux capteurs.

I.5.4.1 Le capteur laser automobile IBEO LD

Ce capteur est le premier prototype réalisé et commercialisé par la société IBEO en 1998. Il a servi d'expérience à son successeur IBEO LDML pour lequel l'unique faisceau horizontal de tir du LD a été remplacé par quatre pour obtenir une perception verticale de 3,2° et compenser ainsi après traitement les pertes de suivi dues au tangage du véhicule. Il a été utilisé dans les projets européens suivant de 1998 à 2001 :

- projet IST CarSense (« *Sensing of Car Environment at Low Speed Driving* ») : l'objet de ce projet était le développement de capteur industriel (capteur radar ACC de Thalès commercialisé par Autocruise et capteur rotatif laser d'IBEO), d'algorithme de fusion de données Laser, radar et image pour une détection de l'environnement frontale du véhicule à des vitesses lentes et d'une architecture multi-capteur de fusion intégrant des réseaux de communication en vue d'améliorer les systèmes d'aide à la conduite (ADAS, Advanced Driver Assistance System). Ce projet a permis de démontrer les capacités d'ACC des capteurs radar et laser en utilisation seule.
- le projet CHAMELEON (« *Pre-crash Application all around the Vehicle* ») : l'objet de ce projet était le développement d'une plateforme sensorielle de détection de collision imminente, autour du véhicule et pour tout type de scénarios [Fuerstenberg, 2001e]. Dans ce projet, le capteur LD a été utilisé pour la détection, le suivi des objets et la classification des objets (voiture, piéton...).

- le projet PROTECTOR (« *Preventive Safety for Un-protected Road User* ») : l'objet de ce projet est l'amélioration de la sécurité des utilisateurs vulnérables de la route (piétons, cyclistes, motocyclistes) en zones urbaines et rurales [Bennetti, 2006].

Notamment lors de ses projets, IBEO a développé et embarqué sur DSP différents algorithmes tels que les traitements suivants,

pour la détection d'objet [Fuerstenberg, 2001a] [Fuerstenberg, 2001b] :

- une segmentation des échos par regroupement de points et représentation de ces groupes selon trois paramètres : point de gauche, point de droite et point ayant la distance la plus proche du capteur.
- un suivi d'objet à l'aide d'un filtre de Kalman prédictif.

pour la classification d'objet [Fuerstenberg, 2001a] [Fuerstenberg, 2001b] :

- une distinction selon des formes d'objets « utilisateurs de la route » classiques (ensemble de données statiques) : camion, voiture, cycliste, moto, piéton ;
- une utilisation des informations passées du suivi (vitesse...) pour relever des ambiguïtés (il est par exemple difficile de classifier une voiture vue selon un de ses angles) ;
- et en cas d'ambiguïtés restantes non relevables, une utilisation d'hypothèses.

Ces traitements ont été développés pour des applications de détection de piéton [Fuerstenberg, 2001a] [Fuerstenberg, 2001b], de conduite automatique (détection d'obstacle et évitement de collision), mais aussi d'assistance au changement de voies en mettant en oeuvre une détection sur 360° avec 3 capteurs IBEO LD placés sur le côté avant droit du véhicule, sur le côté avant gauche et le dernier centré à l'arrière du véhicule [Fuerstenberg, 2001c][Fuerstenberg, 2001d].

Depuis qu'IBEO s'est spécialisé dans la conception de capteur automobile avec son rapprochement de SICK en 2000, on retrouve aujourd'hui des versions de ce capteur (Sick LD PDS) dans la gamme des lasers scanners à temps de vol Sick LD OEM (Laser digital) [SICK_URL]. Les Sick LD OEM sont basés sur une architecture à deux processeurs, l'un intégré pour la mesure laser et la gestion du flux de donnée en entrée/sortie, l'autre connecté, au premier par un bus haut débit, est dédié à l'application et réalise l'acquisition des données et leur traitement. Les différents capteurs de cette famille sont le LD PeCo pour le comptage de personne dans des lieux publics, le LD PDS pour la surveillance de zone en vue de la détection d'intrusion (musée...), le LD NAV pour la conduite de véhicules et de robots (aide à la navigation), le LD Galileo pour guider les avions lors de l'opération d'accostage aux terminaux et le LD CS qui détecte les angles des containers et leur position relative aux remorques des camions afin d'en déduire la position de la grue tractant le container.

Nous présentons maintenant les caractéristiques techniques de l'IBEO LD et celles des enregistrements utilisés.

Caractéristiques techniques du capteur Automobile IBEO LD utilisé

Le capteur « IBEO LD Automotive » (LD pour « Lidar Digital ») qui a servi aux enregistrements est un capteur monoplan.

Il permet une détection d'obstacles entre 1 mètre et 250 mètres sur une ouverture angulaire pouvant aller jusqu'à 270° (figure 18). Pour les obstacles noirs avec une réflectivité d'au moins 5%, la portée est réduite à 40m. La précision sur la mesure de distance est indépendante de la distance et des conditions d'environnement. L'écart-type d'une seule mesure des données est environ ± 5

centimètres (1 Sigma). Le faisceau optique de divergence 5 mrad amène à un chevauchement d'un simple spot laser pour éviter la perturbation dans la zone surveillée.

La communication entre les capteurs de type IBEO et l'ordinateur se fait via deux interfaces séries, la première interface est un bus ARCNET qui permet le transfert de données en temps réel (1440 points couvrant une surface de 360° avec une résolution angulaire de 0,25°); la seconde est un bus CAN (Controller Area Network).



« IBEO LD Automotive Laser Scanner »

Caractéristiques techniques :

- Fréquence de balayage : 10 Hz à 40 Hz
- Angle d'ouverture horizontale : jusqu'à 270° ;
- Portée : jusqu'à 250 mètres pour des cibles réfléchissante, 40 mètres pour des cibles sombres d'au moins 5% de réflectivité
- Résolution : en distance $\pm 5\text{cm}$, angulaire 0,25° à 1,0° (dépend de la fréquence de balayage)
- Classe laser : 1
- Compensation automatique du tangage : NON
- Interface utilisateur [Fuerstenberg, 2001d] : transmission des données objets sur bus CAN ; transmission des données brutes (échos) en temps-réel sur bus ARCnet qui permet l'interconnexion et la synchronisation de deux capteur LD à un système hôte.

Figure 18 : Caractéristiques techniques du capteur rotatif laser « IBEO LD Automotive ».

Caractéristiques des enregistrements des données utilisées de l'IBEO LD

Les enregistrements de la société RTMaps et de l'école des Mines de Paris ont été réalisés dans les conditions suivantes :

- les enregistrements ont été réalisés en milieu urbain avec le capteur intégré à une voiture mobile. Le système RTMaps enregistrait l'ensemble des données délivrées par le capteur LD, ainsi que des données de capteur image.
- monté sur le véhicule, l'angle d'ouverture du capteur est de 160°. Sa résolution angulaire est de 0,25°.

I.5.4.2 Les capteurs de surveillance Sick LMS 200

Les capteurs LMS 2xx (Laser Measurement Systems) de Sick, commercialisés depuis 1994, sont des capteurs de mesures utilisés en intérieur ou extérieur selon la version (« INDOOR » ou

« OUTDOOR ») et principalement utilisé sur support non mobile. Ils ont été conçus pour des applications de sécurité en milieu industriel.

Le LMS 200 (180°, 80m), que nous avons utilisé, et le LMS 291 qui diffère peu, font partie de la famille des capteurs dit INDOOR au même titre que les LD OEM (360°, 250m), LD PDS (360°, 34m), et le LMS 400 (70°, 3m). Ils ont été développés pour un balayage d'un environnement 3D avec une grande précision à l'image d'un capteur radar. D'autres capteurs, LMS 211 (90°, 80m), LMS 221 (180°, 80m) et LD-LRS (300°, 250°), sont des capteurs laser de Sick dit OUTDOOR conçus pour la détection et la classification de véhicule, la protection d'objet, la manutention de container et la mesure de marchandises en vrac dans des abris enterrés [LMS_URL].

Outre son utilisation dans le projet RAVIOLI, voici quelques autres utilisations d'un capteur LMS 2xx en France sur un véhicule mobile :

- un LMS 200 est utilisé dans le projet SAACAM (Systèmes Actifs d'Aide à la Conduite pour Améliorer la sécurité automobile, 2000-2004 [Brassart, 2005][Izri, 2004a&b]) dans le cadre du pôle régional DIVA (DIagnostic et Véhicules Avancés) de la région de Picardie. Ce projet d'aide à la conduite s'intéressait à la perception de la situation de conduite avec un télémètre Sick à l'arrière du véhicule, un GPS et une caméra omnidirectionnelle sphérique sur le toit du véhicule et un capteur ABS sur une roue. Le télémètre SICK est utilisé pour récupérer une image des véhicules suiveurs [Izri, 2004a]. Les traitements effectués sur les données brutes du capteur laser sont [Izri, 2004a] :
 - un partitionnement (« clustering ») des points consécutifs pour la détection des objets de l'image réalisé à partir du calcul de la distance séparant un point de son voisin immédiat ;
 - une étape de segmentation pour la détermination des différentes droites constituant une partition réalisée à l'aide de l'algorithme de recherche Duda-Hart ([Crowley, 1989] cité dans [Izri, 2004a]) ;
 - une étape de filtrage débutant par la suppression des partitions dont le nombre de points n'est pas suffisant pour conclure à la nature d'un objet, puis par le regroupement de droites pour ne former qu'un objet en fusionnant d'une part les droites alignées d'un angle de $\pm 10^\circ$ et d'autre part les droites orthogonales selon certains critères.
- l'INRIA Rhône-Alpes a utilisé des capteurs LMS 291 [Yguel, 2007][Macek, 2008] et 221 [MobiVIP, 2006] à l'occasion de différents projets.
 - dans le cadre des travaux sur le problème de la localisation et de la mise en correspondance simultanée (SLAM – Simultaneous Localisation and Mapping), quatre capteurs LMS 291 ont été embarqués aux quatre coins d'un camion long tractant un gros conteneur chaud en métal [Yguel, 2007]. Les données ont été utilisées pour étudier la construction d'une représentation des données télémétriques en utilisant une représentation basée sur des grilles, en particulier pour proposer une nouvelle stratégie de mise à jour de grilles d'occupation clairsemées dans le but d'éviter une saturation de la mémoire lors de l'exécution des algorithmes hiérarchiques développés.
 - dans le cadre du projet MobiVIP du Predit 3 (Véhicules Individuels Publics pour la Mobilité en centre ville), un véhicule cybercar a été équipé à l'avant d'un télémètre LMS

221 et de télémètres ultrasonores afin d'assurer la sécurité de façon autonome du déplacement du véhicule. L'objectif de cette expérimentation de transport autonome tel que décrit dans [MobiVIP, 2006] était la validation des véhicules dans une foule, celle de l'acceptation des véhicules par les utilisateurs et l'acquisition d'un retour d'expérience d'une part sur les améliorations des interfaces et des véhicules et d'autre part sur les organes de sécurité.

- dans le cadre d'un système de conduite autonome [Macek, 2008], l'Institut Fédéral suisse de Technologie de Zürich et l'INRIA ont équipé un véhicule passager SmartTer d'un capteur IBEO Alasca XT situé à l'avant du véhicule, de deux capteurs Sick LMS 291 placés sur le toit et chargés de la protection des coins du véhicule et d'une caméra omnidirectionnelle Sony, également sur le toit, pour réaliser une détection de l'environnement du véhicule. Un DGPS (« *Differential Global Positioning System* »), une centrale inertie (IMU « *Inertial Measurement Unit* »), un gyroscope optique, des codeurs de roues et un capteur d'angle de braquage ont été utilisés pour obtenir par fusion une localisation précise du véhicule.

Cette rapide présentation faite de l'utilisation de capteur LMS pour la robotique mobile, nous présentons maintenant les caractéristiques techniques du LMS[®] 200 et celles des enregistrements réalisés à l'ULCO.

Caractéristiques techniques du capteur SICK LMS[®] 200 utilisé

Le capteur Sick LMS 200 est un capteur INDOOR. Il a une ouverture angulaire de 180° avec un pas de balayage programmable de 0.25°, 0.5° ou 1° (figure 19). Sa portée maximale est de 80 mètres, elle dépend cependant de la réflectivité de l'objet. Selon la notice constructeur, les capteurs LMS délivrent des mesures en distance avec une erreur systématique (sur les gammes totales de réflectivité, de portée et de température) de +/-15mm en version intérieure et de +/-30mm en version extérieure, erreur à laquelle il faut ajouter une erreur de +/-10 mm provenant de la résolution en distance du capteur. Le constructeur garantit une répétabilité angulaire n'entraînant pas d'erreur sur l'angle. La précision peut être améliorée en calculant la valeur moyenne statistique sur un ensemble de balayage du capteur selon la formule : \sqrt{n} (avec n le nombre de balayages, soit le nombre de mesures du même point).

Deux interfaces séries existent pour transférer les informations du capteur de type LMS vers un ordinateur et vice versa. La première interface série est le RS232 à une vitesse de transmission de l'ordre de 9600 à 38400 bauds, ainsi que la deuxième est le RS422, elle permet la transmission à une vitesse peut atteindre de 500k bauds. La fréquence d'acquisition des données dépend de l'angle d'ouverture utilisé ainsi que la résolution angulaire.

Caractéristiques des enregistrements de données faits avec le Sick LMS 200

Les données utilisées de ce capteur ont été fournies par l'UTC de Compiègne dont le capteur a été monté sur un véhicule mobile. Les acquisitions ont été réalisées en zone urbaine. Les paramètres utilisés ont été les suivantes : un angle d'ouverture de 180° avec un angle de résolution de l'ordre de 1°.



« SICK LMS© 200 »

Caractéristiques techniques :

- Fréquence de balayage : 10 Hz à 40 Hz
- Angle d'ouverture horizontale : 180°
- Portée : 80m (dépend de la réflectivité)
- Résolution : en distance 10 mm, erreur systématique ± 15 mm, erreur statique (1 sigma) 5 mm ; angulaire 1...0,25°
- Classe laser : 1
- Interface utilisateur : RS 232, RS 422

Figure 19 : Caractéristiques techniques du capteur rotatif laser « SICK LMS© 200 ».

La figure 20 montre la capture d'une scène vue par le capteur Sick LMS 200 mais convertie en coordonnées cartésiennes et celle de cette même scène vue par une caméra CCD.

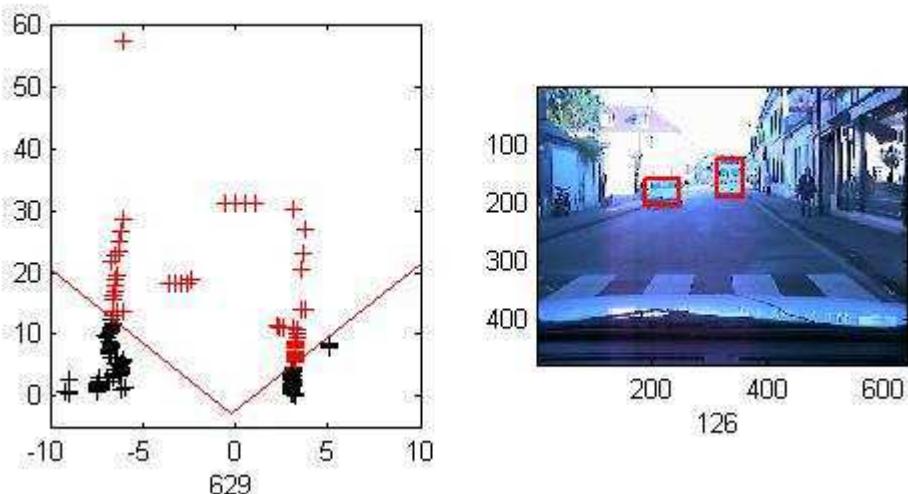


Figure 20 : Illustration pour la même scène des mesures délivrées par un SICK LMS 200 converties en coordonnées cartésiennes et l'image vidéo correspondante.

Après avoir dans un premier temps introduit le contexte général de notre étude, nous avons détaillé dans ce chapitre l'ensemble de la chaîne de détection et suivi multi-objets à partir de capteurs télémétriques. Nous avons notamment décrit les éléments qui la constitue, en insistant en particulier sur deux points clés que nous avons développé dans nos travaux : la partie estimation/association et la partie capteur (directement liée à la détection).

Pour la partie estimation, nous avons pris le parti de présenter uniquement les méthodes de filtrage les plus populaires : filtrage de Kalman/Kalman étendu, filtrage "unscented" et filtrage particulaire. A ce propos, même si dans notre approche nous n'avons volontairement pas abordé les méthodes de Monte Carlo séquentielles (sans perdre toutefois en généralité, car nous nous sommes focalisés sur la partie intégration du contexte et détection), il nous a paru difficile d'en faire l'impasse dans une étude bibliographique.

Dans le contexte multi-objets de l'étude un des points difficiles concerne l'étape d'association qui vise à alimenter la partie filtrage en fournissant au suivi de chaque objet les mesures associées

convenables. Parmi l'ensemble des approches envisageables, deux types de méthodes ont fait leurs preuves dans la littérature : les méthodes d'association probabiliste de données (PDA, JPDA), que nous avons privilégié dans le cadre de notre étude, et les méthodes MHT.

Finalement, ayant fait de la partie détection un de nos points centraux d'étude (justifiant à elle seule d'un chapitre à part entière dans ce mémoire), il est apparu indispensable de présenter les principes physiques et techniques généraux des capteurs télémétriques de type radar ou lidar.

Chapitre II

Suivi multi-objets avec intégration du contexte capteur/objet

La problématique scientifique que l'on traite dans cette thèse prend sa source dans le projet RaViOLi (Radar et Vision Orientable, Lidar). Ce projet s'inscrit dans une logique de développement d'un système d'assistance au conducteur qui permet à terme de prévenir le conducteur de situations potentiellement dangereuses.

Pour cela, le véhicule est équipé d'un télémètre laser à balayage qui permet de mesurer à chaque tir la distance des objets présents dans la scène (véhicules). Le capteur délivre en particulier des mesures sur des objets spatialement distribués et dotés de leur propre dynamique. D'un point de vue scientifique, plusieurs difficultés sont à considérer.

Nous nous sommes focalisés sur deux points clés de cette problématique :

- la détection des objets présents dans la scène ;
- leur suivi à chaque instant.

Nous proposons donc par la suite, plusieurs méthodes de détection qui permettent d'exploiter la nature spatialement répartie des objets en délivrant une information globale sur la forme.

Par ailleurs, une fois détectés, les objets doivent être suivis à chaque instant afin d'estimer leurs caractéristiques cinématiques.

Nous avons pu constater dans le chapitre précédent que la robustesse du suivi d'objets multiples repose notamment sur les méthodes d'association utilisées. Leur efficacité dépend de plusieurs facteurs dont l'incertitude sur les observations qui est normalement caractérisée selon le capteur utilisé, la probabilité de détection d'objet P_d , l'efficacité de l'étape de filtrage (prédiction) et la méthode de détection.

Un deuxième volet de notre étude concerne la mise en œuvre de méthodes d'association qui intègrent le contexte de la scène. En effet, dans le cas général, les méthodes probabilistes d'associations de données (PDA) exploitent les probabilités de détection de la cible à suivre. Dans le cas des radars pour lesquels ces méthodes ont été initialement développées, on obtient aisément une valeur analytique de cette probabilité de détection [Blackman, 1986]. Dans le cas d'un télémètre laser qui délivre des informations de cibles distribuées, ce calcul devient nettement plus complexe voire irréalisable de manière analytique.

Il est cependant connu qu'une détermination fidèle de P_d influe directement sur les performances de l'algorithme de suivi associé. Notre idée est donc de proposer une méthode de détermination automatique de cette probabilité qui repose sur les réseaux bayésiens. Elle permet en outre d'intégrer des informations contextuelles sur la scène et d'aider à la détermination de cette probabilité.

Les approches ont été appliquées à des situations routières de vitesses élevées, et plus particulièrement sur routes ou autoroutes. Nous avons donc volontairement exclu l'étude de la problématique piéton, qui est plus particulièrement importante en zone urbaine. Par ailleurs, le capteur télémètre adopté pour notre étude est vraisemblablement mal adapté à la détection de tels objets, en raison notamment de leur faible étendue spatiale.

II.1 Détection des objets

II.1.1 Introduction

L'objectif premier est de segmenter les mesures provenant du capteur. Il s'agit de regrouper en sous-ensembles ou groupes de points les mesures acquises au cours d'un échantillonnage de la scène (dans notre cas, un échantillonnage correspond à un balayage de la scène par le capteur). Cette étape permet donc de détecter les objets présents parmi les données fournies par le(s) capteur(s) (figure 21).

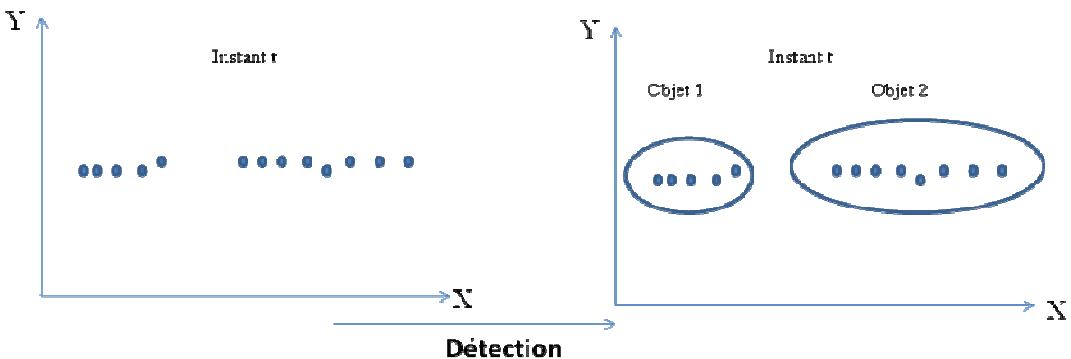


Figure 21: Détection à un instant t .

Cette étape dépend du système de perception qui est mis en œuvre : plus ce système est pertinent et plus il dispose d'informations sur l'environnement perçu, plus la détection des objets pourra être efficace pour la problématique traitée.

Dans [Trassoudaine, 1996], la détection d'obstacles à partir de données laser se déroule en deux étapes : la segmentation en région de l'image 3D puis la reconnaissance des obstacles parmi ces régions. Dans [Lemonde, 2005], la détection d'obstacles est basée sur une représentation 3D de l'environnement issue d'un capteur stéréoscopique. D'autres travaux détectent des piétons en mouvement dans une image 2D grâce à la composante couleur et à une image de référence (sans objet mobile), remise à jour périodiquement [Motamed, 2000].

Pour réaliser cette détection, un regroupement des mesures basé sur la distance euclidienne entre mesures successives et l'application d'un seuil de séparation peut s'avérer suffisant. Cependant, en raison des caractéristiques des données (problème de chevauchement des données présenté au

paragraphe II.5.1.1), il peut se produire une perte de continuité spatiale pour des mesures appartenant à un même objet. Des méthodes d'apprentissage non supervisé (« clustering ») ont alors été envisagées. Ces méthodes cherchent à « trouver les classes naturelles (implicites) pour rassembler des données non étiquetées » [Jardino, 2005].

La validation des méthodes de détection se fait par le biais du taux de détection. Cette grandeur est évaluée comme la fraction du nombre d'objets détectés sur le nombre d'objets réellement présents et pertinents pour le suivi. Les fausses alarmes, où l'on détecte un objet qui en réalité n'est pas présent ou les non détections d'objets réellement présents pénalisent ce taux de détection. Le problème de détection se pose alors en terme de compromis entre ces deux considérations.

L'agrégation de mesures proches reste un problème délicat. Dans le cas d'occultation partielle d'un objet, l'algorithme doit agréger les mesures appartenant réellement à l'objet pour ne faire qu'une seule détection. Il doit toutefois être également capable de discriminer deux objets proches. Le problème de détection se pose alors en terme de compromis entre ces deux considérations.

Nous présentons par la suite une méthode de détection supervisée et deux méthodes de détection non supervisées ainsi que pour chacune d'entre elles, une variante proposée. Des résultats comparatifs concernant la qualité de la détection et la vitesse d'exécution permettront d'évaluer les performances relatives des méthodes retenues.

II.1.2 Méthodes supervisées

On appelle méthode de détection ou de classification supervisée une méthode utilisant une connaissance *a priori* ou des exemples pour mener à bien, c'est-à-dire diriger, guider, la classification. Dans notre cas, une méthode est supervisée si elle nécessite la connaissance *a priori* du nombre d'objets : nous avons appliqué la méthode des K-moyennes (paragraphe II.1.2.2). D'autres méthodes sont dites supervisées dans la littérature mais par rapport à d'autres critères de classification que celle de la connaissance du nombre d'obstacles. Nous exposons dans un premier temps rapidement quelques-unes de ces méthodes à titre d'exemple (paragraphe II.1.2.1).

II.1.2.1 Exemple de méthodes supervisées

Plusieurs méthodes de détection supervisées existent dans la littérature. Parmi ces méthodes on peut citer :

- Hinneburg et Keim ont proposé l'algorithme DENCLUE (DENsity based CLUstEring) [Nackache, 2004] basé sur des notions de fonction d'influence (influence function) et d'attracteurs de densité (density attractor). La fonction d'influence traduit l'influence d'un objet dans son voisinage. La densité globale (fonction de densité) est la somme des fonctions d'influence de tous les points. Les classes sont déterminées par des attracteurs de densité qui sont des maxima locaux de la fonction de densité. Un choix de fonction d'influence peut être la mesure de la distance $d(x,y)$ entre objets [Nackache, 2004].
- [Ouarab, 1999] utilise une méthode de classification hiérarchique pour une classification supervisée d'images satellitaires. Cette méthode nécessite la connaissance et la nature des objets au sol. La méthodologie adoptée consiste en la détermination des zones homogènes dans l'image par les tests statistiques de Wilcoxon et les supports des enveloppes convexes et le regroupement de ces zones par des méthodes de classification hiérarchique telles que

celles du « Single-linkage » (qui définit la distance entre deux classes comme la distance minimum entre elles, soit celle des deux points les plus proches), du « Complete-linkage » (qui la définit comme la distance maximum entre elles, soit celle des deux points les plus éloignés) et de l’« Average-Linkage » (qui la définit comme la moyenne entre toutes les paires d’entités des deux classes).

- les méthodes des arbres de décision sont très utilisées pour l’apprentissage, en particulier les algorithmes ID3 [Quinlan, 1986] et C4.5 [Quinlan, 1993], également populaires pour la classification supervisée de documents [Freeman, 1998]. Comme toute méthode d’apprentissage supervisée, les arbres de décision utilisent des exemples. Si l’on doit classer des documents dans des catégories, il faut construire un arbre de décision par catégorie. Pour déterminer à quelle(s) catégorie(s) appartient un nouveau document, on utilise l’arbre de décision de chaque catégorie auquel on soumet le document classé. Chaque arbre répond Oui ou Non (il prend une décision). Concrètement chaque nœud d’un arbre de décision contient un test (un If … Then) et les feuilles ont les valeurs Oui ou Non.
- la classification probabiliste suppose que les observations x_1, \dots, x_n d’un ensemble E des observations à classer sont des réalisations d’un vecteur aléatoire X à valeurs dans \mathbb{R}^p (p variables quantitatives) [Bouveyron, 2006]. Elle suppose en outre que les valeurs z_1, \dots, z_n , décrivant l’origine des observations x_1, \dots, x_n , sont des réalisations de la variable aléatoire Z à valeurs dans $\{1, \dots, k\}$. Ainsi, le fait de dire que x est une réalisation de la variable aléatoire X conditionnellement au fait que $Z = i$ revient à dire que l’observation x appartient à la $i^{\text{ème}}$ classe C_i . Ils introduisent également le vecteur aléatoire $S \in \{0, 1\}^k$ tel que si $Z = i$ alors $S = (0, \dots, 0, 1, 0, \dots, 0)$ où le $i^{\text{ème}}$ terme vaut 1, et ce pour $i = 1, \dots, k$. Ce cadre probabiliste permet de construire la règle de décision (pour faire l’association des observations à des classes) optimale δ^* , dite également règle de Bayes, qui minimise le risque conditionnel $R(\delta|x)$ pour chaque observation x . En associant un coût nul à une bonne affectation et un coût de 1 à une mauvaise affectation, le risque conditionnel s’écrit :

$$R(\delta|x) = 1 - P(Z = \delta(x)|X = x).$$

- La règle δ^* consiste donc à affecter l’observation x à la classe la plus probable *a posteriori* :

$$\delta^*(x) = \operatorname{argmax}_{i=1, \dots, k} P(Z = i|X = x)$$

- Cette règle porte le nom de MAP pour maximum *a posteriori*. La règle de décision repose donc sur les probabilités *a posteriori* et c’est la manière de calculer ces probabilités qui différencie deux approches de la classification probabiliste : l’approche discriminative et l’approche générative. La première modélise directement la probabilité *a posteriori* $P(Z|X)$ en cherchant à définir la frontière entre les classes. L’approche générative, quant à elle, cherche tout d’abord à modéliser la distribution jointe $P(X, Z)$ et en déduit ensuite la règle de classification

$$\text{par la formule de Bayes } (P(Z|X) = \frac{P(Z)P(X|Z)}{P(X)} \propto P(Z)P(X|Z)).$$

- la méthode des K-moyennes est un outil de classification classique qui permet de séparer un ensemble de données en k classes homogènes [Jain, 1999]. Elle est souvent utilisée dans la

segmentation des images (Satellitaire, vidéos,..) et elle a été introduite par J. McQueen en 1971.

Dans notre cas, nous travaillons sur le suivi d'objets sur autoroute pour lequel le nombre d'objets à suivre est variable et n'est pas connu *a priori*. Ces méthodes sont donc peu adaptées à notre problématique.

II.1.2.2 K-means (K-moyennes)

Toutefois, afin d'étudier les performances d'une méthode de référence en classification, nous avons choisi de tester la méthode des K-moyennes (K-means) sur notre jeu de données, en intégrant la connaissance *a priori* du nombre d'objets visibles.

La méthode des *K*-means est un outil de classification qui permet de répartir un ensemble de données en *k* groupes. La difficulté de cette méthode est le choix *a priori* des *k* centres des groupes qui peut avoir une influence non négligeable sur la convergence de l'algorithme et donc les résultats. Cette méthode est très utilisée dans de nombreux domaines dont la segmentation d'image pour regrouper les zones homogènes de l'image.

Le principe de la méthode est le suivant : à partir d'une connaissance *a priori* des *k* centres de gravité des groupes d'objets, chaque mesure est comparée et affectée à un groupe selon un critère de distance minimale entre cette mesure et les centres des groupes. Cette comparaison puis affectation terminée, le centre de gravité de chaque groupe est calculé à nouveau jusqu'à convergence vers un résidu négligeable. On trouvera le détail de la méthode des *k*-means dans [Jain, 1999].

Pour notre étude, cette méthode a été adaptée pour être exécutée sur des données télémétriques (radar) pour lesquelles on connaît le nombre maximal d'objets présents.

Algorithme des K-means (K-moyennes) testé :

Pour chaque période d'acquisition, la méthode regroupe les mesures issues d'un même objet de la scène. Les *entrées* et *sorties* de cette fonction sont :

- entrées : les vecteurs d'abscisses (vec_abs)_{*i*} et d'ordonnées (vec_ord)_{*i*} qui correspondent au balayage au temps « *i* » ($balayage$)_{*i*}.
- sorties : l'ensemble des groupes (clusters) $\{clust_t\}_i$ qui représentent les objets de la scène pour ce balayage ($balayage$)_{*i*}.

L'algorithme est le suivant :

- 1- Phase d'initialisation : initialisation des *k* centres des groupes $\{clust_t\}$ puis affectation de chaque point à un des *k* groupes $\{clust_t\}$ selon un critère de distance minimale entre le point et les centres des *k* groupes.
 - 2- Calcul (rafraîchissement des valeurs) des barycentres de chacun des *k* groupes $\{clust_t\}$:
- $$C_i = \text{card}(clust_i)^{-1} \times \sum_{z \in clust_i} z$$
- 3- Affectation de chaque point au groupe $clust_k$ dont le centre est le plus proche :
- $$clust(z_i) = \underset{p \in 1, \dots, k}{\text{argmin}} \|z_i - C_p\|$$

4- Répétition des étapes 2 et 3 jusqu'à ce que la valeur des barycentres converge vers une valeur stable : les barycentres à l'étape t sont les mêmes à l'étape $t-1$ à un ϵ près.

Le résultat de la détection obtenu à partir de données simulées est représenté sur la figure 22. Les données simulées proviennent d'un simulateur radar en coordonnées polaires décrit dans [Wahl, 1997].

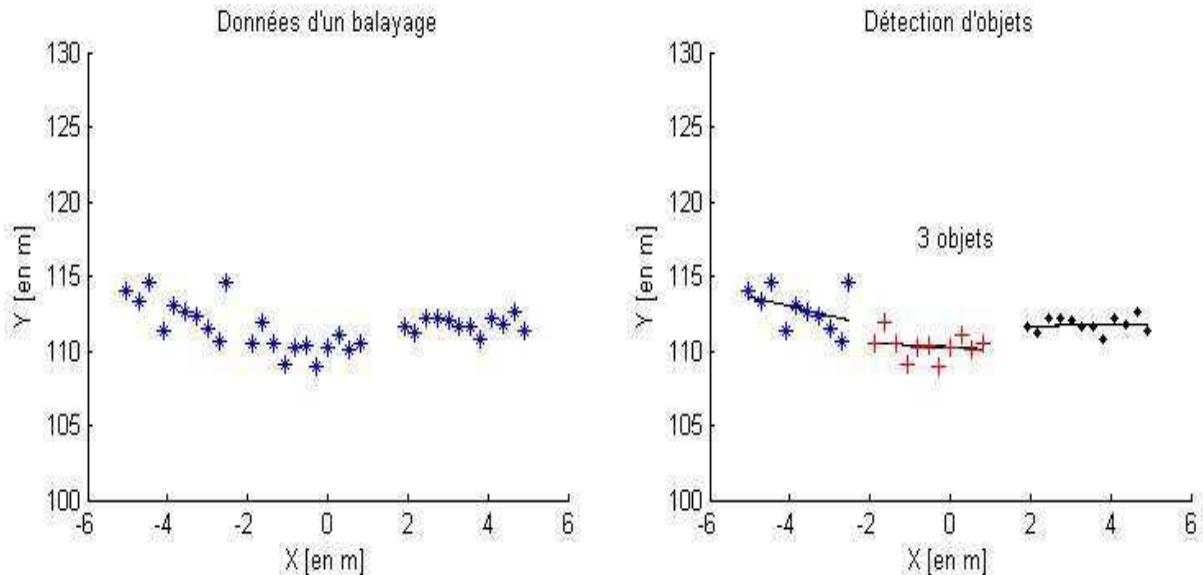


Figure 22: Exemple de détection d'objets réalisée avec K-means.

Malgré leur efficacité dans ce cas supervisé, ces méthodes sont peu adaptées au problème de transport pour lequel le trafic est totalement imprévisible quant aux nombres d'objets présents. C'est donc naturellement vers des méthodes non supervisées que nous nous sommes tournées.

II.1.3 Méthodes non supervisées

Les méthodes non supervisées sont des méthodes qui ne bénéficient pas d'une quelconque connaissance *a priori* sur le système étudié permettant d'aider à la convergence du système.

Le paragraphe II.1.3.1 donne un rapide aperçu de différentes méthodes non supervisées rencontrées dans la littérature. Dans les deux paragraphes suivants, nous nous concentrerons sur la résolution de notre problème par les deux méthodes suivantes :

- 1) la première méthode, expliquée au paragraphe II.1.3.2 est adaptée de la méthode de classification hiérarchique, habituellement utilisée pour la segmentation d'image,
- 2) la deuxième méthode, exposé au paragraphe II.1.3.3, est dérivée de la méthode des nuées dynamiques.

II.1.3.1 Méthodes de classification non supervisées rencontrées dans la littérature

Plusieurs travaux traitent de la détection dans le cadre de classification non supervisée, parmi ces méthodes on peut citer :

- [Williamson, 1999] utilise une caméra stéréoscopique trinoculaire longue portée pour détecter des objets de petites tailles sur la route. L'équation utilisée qui décrit la distance maximale théorique à laquelle un obstacle peut être détecté dans des conditions idéales est

$$z_o = \frac{h_o k}{h_c \Delta} \text{ où } h_o \text{ est la hauteur de l'obstacle, } h_c \text{ est la hauteur de la caméra, } k \text{ est la distance}$$

par laquelle le système distingue un pixel de disparité (à environ 4250 m pour leur système) et Δ le nombre des pixels de disparités différentes qui sont détectables. Afin de détecter les obstacles, il calcule les résultats stéréoscopiques à chaque pixel sur une région locale de l'image pour laquelle chaque pixel est à la même distance de la caméra. Le résultat est calculé par une méthode traditionnelle en vision stéréoscopique qui utilise des plans verticaux. Un obstacle, un trottoir et un bâtiment au fond d'une image sont tous identifiés comme des surfaces verticales par cette méthode.

- [Takizawa, 2004] utilise un système de deux capteurs, composé d'une caméra et d'un capteur radar laser à balayage (capteur SLR, Scanning Laser Radar). À l'aide d'une projection perspective, les données en sorties du SLR sont reportées sur le plan de l'image issue de la caméra. Pour réduire la complexité de l'étape de fusion avec le vecteur de l'image d'entrée, il calcule un histogramme des contours de la région d'intérêt correspondant au centre de l'image d'entrée comme le produit de l'histogramme en x et de celui en y . Cet histogramme est alors lissé par un filtre passe-bas avant extraction des points d'intérêt représentés par des sommets (peak). Les impacts du SLR sont ensuite projetés sur l'image précédente pour refléter un niveau de puissance du signal réfléchi, et déterminer ainsi des primitives télémétriques. Si les impacts du SLR correspondent à des données longues ou moyennes portées, la résolution des données SLR est faible, comparée à celle de l'image et les données manquantes sont ainsi remplacées par voisinage et lissage. La détection des véhicules présents s'effectue alors à l'aide d'un filtre de Kalman qui utilise à la fois les données image et les données « puissance » du SLR obtenues précédemment dans un processus de fusion de ces deux types d'information.
- [Mendes, 2004] utilise un capteur laser à balayage LMS 200 dans la conception d'un système d'évitement de collisions pour un véhicule CyberCar. Il met en œuvre une méthode de détection basée sur une recherche de segments dans un ensemble de mesures, construisant ainsi des droites servant au groupement d'ensemble de points qui représentent chacun un objet. Le principe est classiquement de segmenter les mesures d'un balayage en plusieurs groupes en fonction de la distance entre les impacts consécutifs (*clustering*), puis d'ajuster l'ensemble des points appartenant au *cluster* aux paramètres de la droite. L'originalité de ce travail réside dans l'algorithme d'évitement de collision qui repose alors sur le calcul du temps-à-collision du déplacement de chaque objet mobile détecté.
- [Trassoudaine, 2005] détecte des obstacles dans des images 3D délivrées par un télémètre laser 3D LMSZ210-60. La détection d'obstacles correspond à l'extraction des primitives dans les images 3D. Cette extraction se déroule en deux étapes : La première consiste en une segmentation en régions de l'image 3D et la seconde consiste à reconnaître des obstacles parmi ces régions.
- [Giai-Checa, 1993] a utilisé un algorithme de détection d'objets qui permet de détecter des objets en mouvement à partir de deux images successives en utilisant les contours (modélisés en segments) et les paramètres de leur mouvement 2D. Il préconise l'analyse ensemble par ensemble des groupes des segments avant d'effectuer un regroupement.
- [Aufrère, 2000] présente une méthode permettant de déterminer, par vision monoculaire embarquée, la voie de circulation du véhicule. Cette méthode est basée sur une

reconnaissance récursive des bords de route guidée par un modèle probabiliste défini par un vecteur représentant les abscisses respectives des bords gauche et droite de la route dans l'image et sa matrice de covariance associée. Le vecteur et la matrice de covariance définissant le modèle initial sont établis par une phase d'apprentissage, basée sur des connaissances *a priori*, dont le but est de fournir les valeurs initiales. La reconnaissance se fait dans des zones d'intérêt optimales déduites de la mise à jour courante du modèle. La route est considérée reconnue lorsqu'un nombre minimum de primitives est atteint.

- [Labayrade, 2003] propose une nouvelle approche coopérative de fusion de la détection provenant de la stéréovision et d'un capteur laser à balayage, afin de prendre avantage des caractéristiques de chacun de deux capteurs pour effectuer une détection en temps-réel robuste et précise des objets multiples présents dans la scène. La détection d'objets dans les images stéréoscopiques est basée sur l'extraction des bords non-horizontaux de deux images stéréoscopiques dont seules les parties communes sont conservées à l'aide d'une corrélation normalisée, afin d'obtenir une carte de disparité clairsemée. La disparité est accumulée le long des lignes de balayage pour obtenir la « v-disparité » de l'image en niveau de gris. Dans cette « v-disparité », le plan de la scène d'intérêt est projeté le long d'une droite. La route est caractérisée comme un ensemble de plans et les obstacles comme des plans verticaux. L'extraction des lignes droites dans la « v-disparité » de l'image amène à extraire la surface de la route et les obstacles ainsi que leur hauteur. La largeur des obstacles est évaluée à partir d'un autre terme de l'image (« u-disparité ») en effectuant une analyse de connectivité au niveau des valeurs de disparité qui correspondent à des obstacles. La détection des objets dans les données télémétriques est basée, dans ce travail, sur le regroupement des mesures appartenant à chaque obstacle de la scène en utilisant une distance de Mahalanobis classique.
- dans [Lemonde, 2005], la détection d'objets est basée sur une représentation 3D de l'environnement issue d'un capteur stéréoscopique. Cette méthode est réalisée en deux étapes : Dans la première étape, le devers ou l'angle de roulis du véhicule est supposé nul et selon le résultat de l'estimation des paramètres de la route, l'auteur évalue s'il est envisageable de négliger ce devers ou ce roulis. Dans une seconde étape et dans le cas où ce n'est pas possible, les images sont corrigées avant la phase de détection d'obstacles. Sans tenir compte du devers, l'objectif est de construire un profil longitudinal de la route sur la base d'une méthode qui repose sur l'étude une à une des lignes de l'image. En l'absence d'obstacles, de devers et de roulis, tous les points d'une ligne correspondent à des points de la surface de la route qui sont alors à une même profondeur.

II.1.3.2 Détection par classification hiérarchique ascendante

L'objectif est ici le regroupement de classes existantes en une (ou plusieurs) classe(s) hiérarchiquement supérieure(s) en nombre de points selon un critère de distance. Cet algorithme de classification est souvent utilisé dans l'analyse des données et la segmentation des images [Jain, 1999] [Su, 2005]. Il part des singletons (initialisation de chaque groupe ou « cluster » par un point), puis il procède par agrégations successives. Cette méthode est basée sur le calcul de la distance euclidienne entre les couples de groupes :

$$D(\text{clust}_i, \text{clust}_j) \quad \forall \quad j > i \quad \text{pour } i=1, \dots, n \text{ et } j=1, \dots, n,$$

où n est le nombre de groupes lors de l'étape en cours.

Les groupes d'un couple qui sont très proches, c'est-à-dire dont la distance minimale est inférieure à un seuil, sont alors fusionnés.

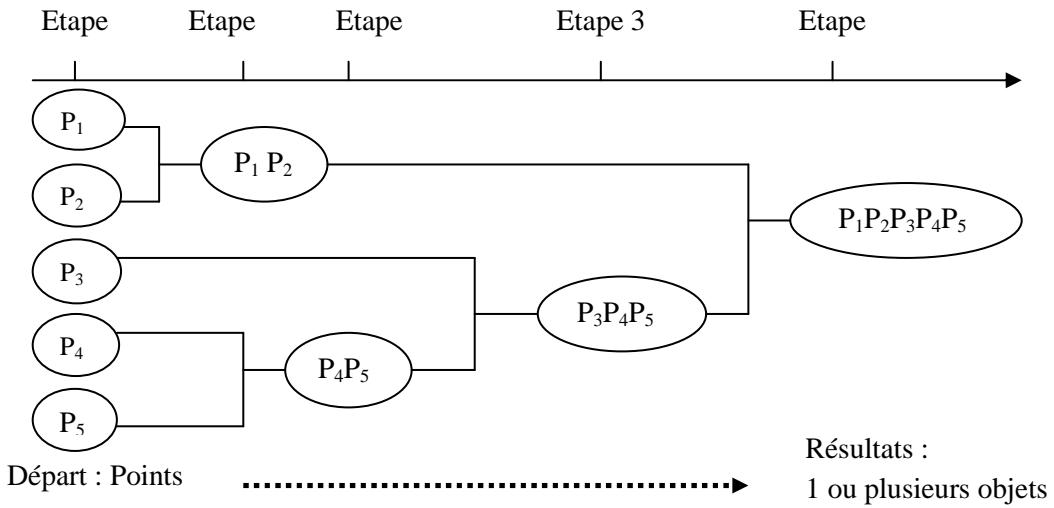


Figure 23 : Principe de la méthode de classification hiérarchique.

On réitère ensuite l'opération du calcul des distances entre les groupes existants et les groupes éventuellement à regrouper jusqu'à ce que toutes les distances entre groupes formés soient supérieures à un seuil fixé par l'utilisateur. Ce seuil peut également être déterminé en fonction de l'erreur commise sur les mesures provenant du capteur.

L'inconvénient de cette méthode est le temps d'exécution du programme qui peut s'avérer prohibitif puisqu'il faut évaluer, lors de chaque étape, toutes les agrégations possibles de deux groupes (centres de groupes) parmi n , soit $n(n-1)/2$ possibilités.

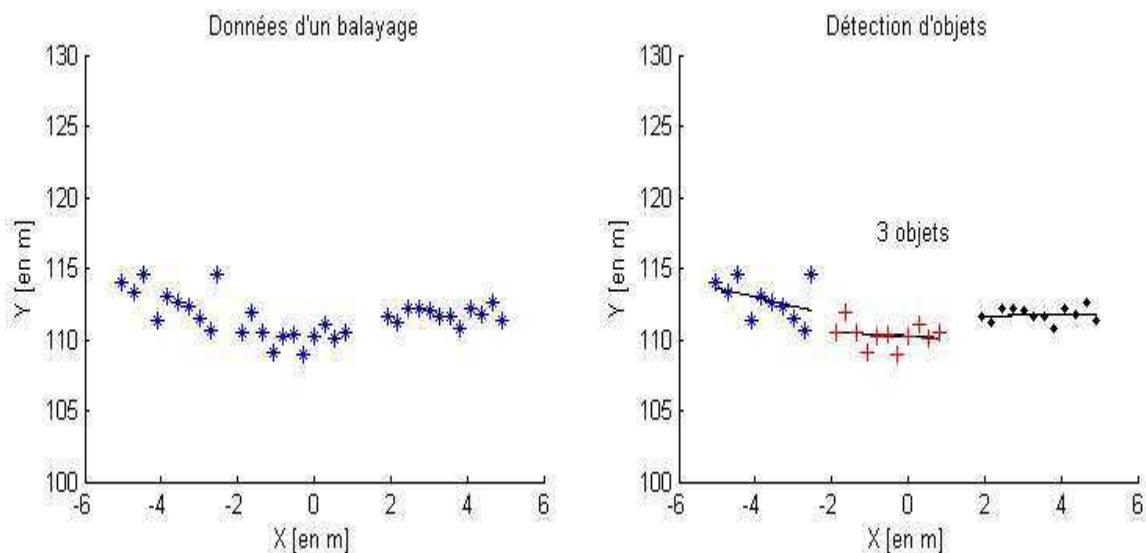


Figure 24 : Exemple de détection d'objets par la méthode de classification hiérarchique.

La figure 23 illustre le principe de la méthode de classification hiérarchique qui part des singletons (points P_i de l'étape 0) pour arriver à la construction de groupes qui correspondent aux objets d'une scène (étape 4 sur le schéma).

La figure 24 de droite montre le résultat de la détection en utilisant cet algorithme sur les données simulées présentées en partie gauche.

Variante de l'algorithme hiérarchique

Une autre méthode, inspirée de la précédente, peut être envisagée. L'algorithme s'initialise sur le premier point et cherche le point le plus proche situé à une distance inférieure à un seuil choisi afin de décider de la séparation des objets d'une scène. L'algorithme fait alors le regroupement de ces points et calcule le centre de groupe obtenu. Il réitère alors la démarche avec les points qui ne sont pas encore regroupés et le centre de groupe obtenu jusqu'à ce que la distance entre le groupe et le point envisagé dépasse le seuil. Puis, l'algorithme sélectionne le dernier point non regroupé comme origine d'un nouveau groupe.

Les résultats obtenus par cette variante sont les mêmes que ceux obtenus par l'algorithme de classification hiérarchique ascendante. Le seuil peut également être déterminé en fonction de l'erreur des mesures.

Cependant, cette variante est basée sur une formation de groupement d'impacts groupe après groupe. Elle réduit significativement le nombre de distances calculées et est donc moins coûteuse en temps de calcul. Elle sera préférée à la première méthode si la vitesse d'exécution doit être privilégiée. En revanche, la première variante est beaucoup plus discriminante lorsque les objets sont très proches ou se chevauchent donnant alors de meilleurs résultats.

II.1.3.3 Détection séquentielle (issue de l'algorithme des nuées dynamiques)

Pour cet algorithme, un groupe est initialisé pour la première mesure du balayage en cours. On considère cette mesure comme le centre d'un cercle de rayon R (R est équivalent à un seuil en distance euclidienne pour l'affectation d'une mesure au groupe en formation). Des distances sont calculées entre la mesure (*i.e.* le centre du cercle) et toutes les autres mesures non encore regroupées. Les mesures dont la distance est inférieure ou égale à R sont affectées au groupe en formation. On réitère la démarche avec les points qui ne sont pas encore regroupés jusqu'à ce que tous les impacts soient affectés à un groupe.

Le résultat obtenu par cet algorithme est présenté en partie droite de la figure 25, les données initiales apparaissent sur la partie gauche de cette même figure.

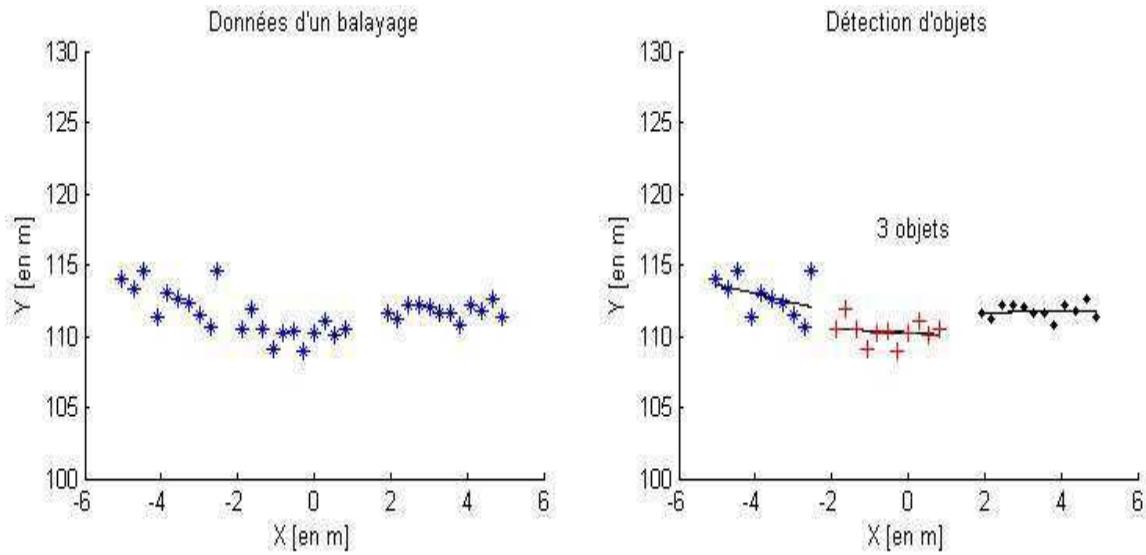


Figure 25 : Exemple de détection d’objets par la méthode séquentielle dérivée de la méthode des nuées dynamiques.

Lors de l’exécution de cet algorithme, on a constaté un temps de calcul important. Pour cette raison, une variante est proposée afin de minimiser le temps de calcul en limitant le nombre d’itérations.

Variante de l’algorithme de détection séquentielle

Cette méthode de détection est divisée en deux phases :

- la première étape définit un groupe comme un cercle dont le centre correspond à la première mesure d’un balayage et le rayon est le seuil en distance pour l’affection d’un autre point à ce groupe. Les autres mesures sont affectées au groupe en formation, si la distance avec le centre du cercle courant est inférieure ou égale au rayon du cercle. Dans le cas où la distance dépasse le seuil, la mesure courante sera le centre d’un nouveau cercle et donc l’origine d’un nouveau groupe.
- la seconde étape de cet algorithme cherche à regrouper les groupes déjà existants. En effet, en raison des phénomènes de chevauchement (*cf.* § II.5.1.1), il est possible de regrouper des groupes qui ne sont pas forcément adjacents. L’idée est donc de ne pas se limiter au groupe suivant lors du test en distance mais aux c groupes suivants (c étant un paramètre de la méthode). On garantit ainsi un meilleur regroupement pour extraire les objets présents. Pour chaque groupe, on calcule la distance entre le centre du cercle et le centre du cercle représentant le groupe sélectionné. Si la distance est inférieure ou égale à deux fois la distance seuil (le rayon d’un cercle), les groupes sont agglomérés. On obtient ainsi des groupements qui représentent les objets extraits de la scène.

Les résultats de cet algorithme sont illustrés figure 26. Les données à traiter (figure 26-a) permettent de bien faire apparaître les différentes étapes de construction des groupes. Les résultats intermédiaires (groupes avant fusion) issus de l’étape 1 sont montrés sur la figure 26-b. Chacune de ces classes est représentée par une ellipse (de centre \star étoile) dont les axes sont calculés à partir des incertitudes des mesures appartenant au groupe. Les résultats de la deuxième étape de cet algorithme sont présentés sur la figure 26-c. On voit bien apparaître la fusion des différents groupes déjà existants en groupes d’impacts représentant les objets de la scène.

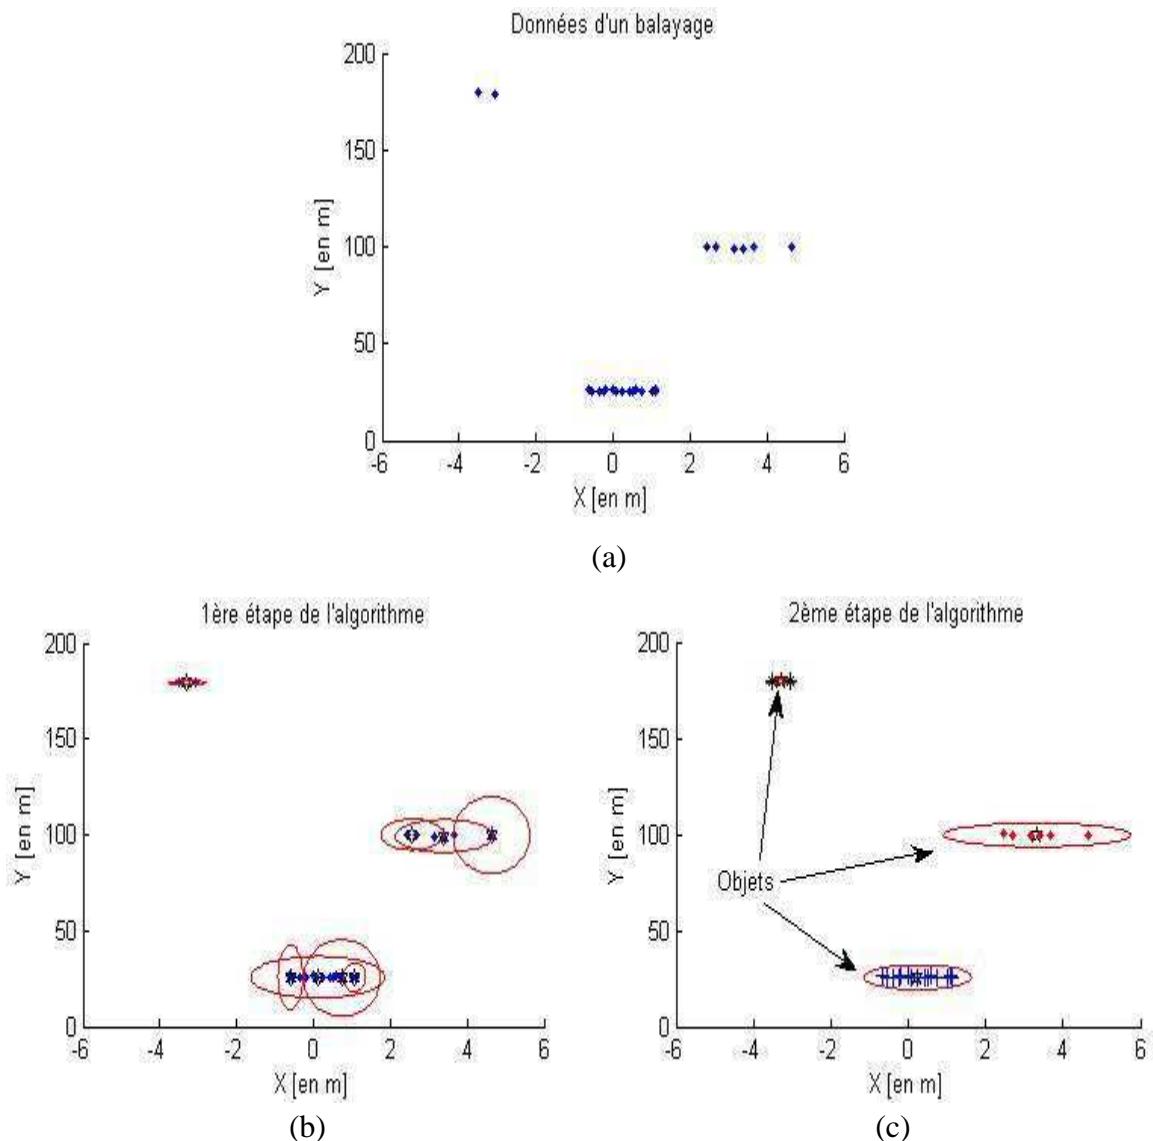
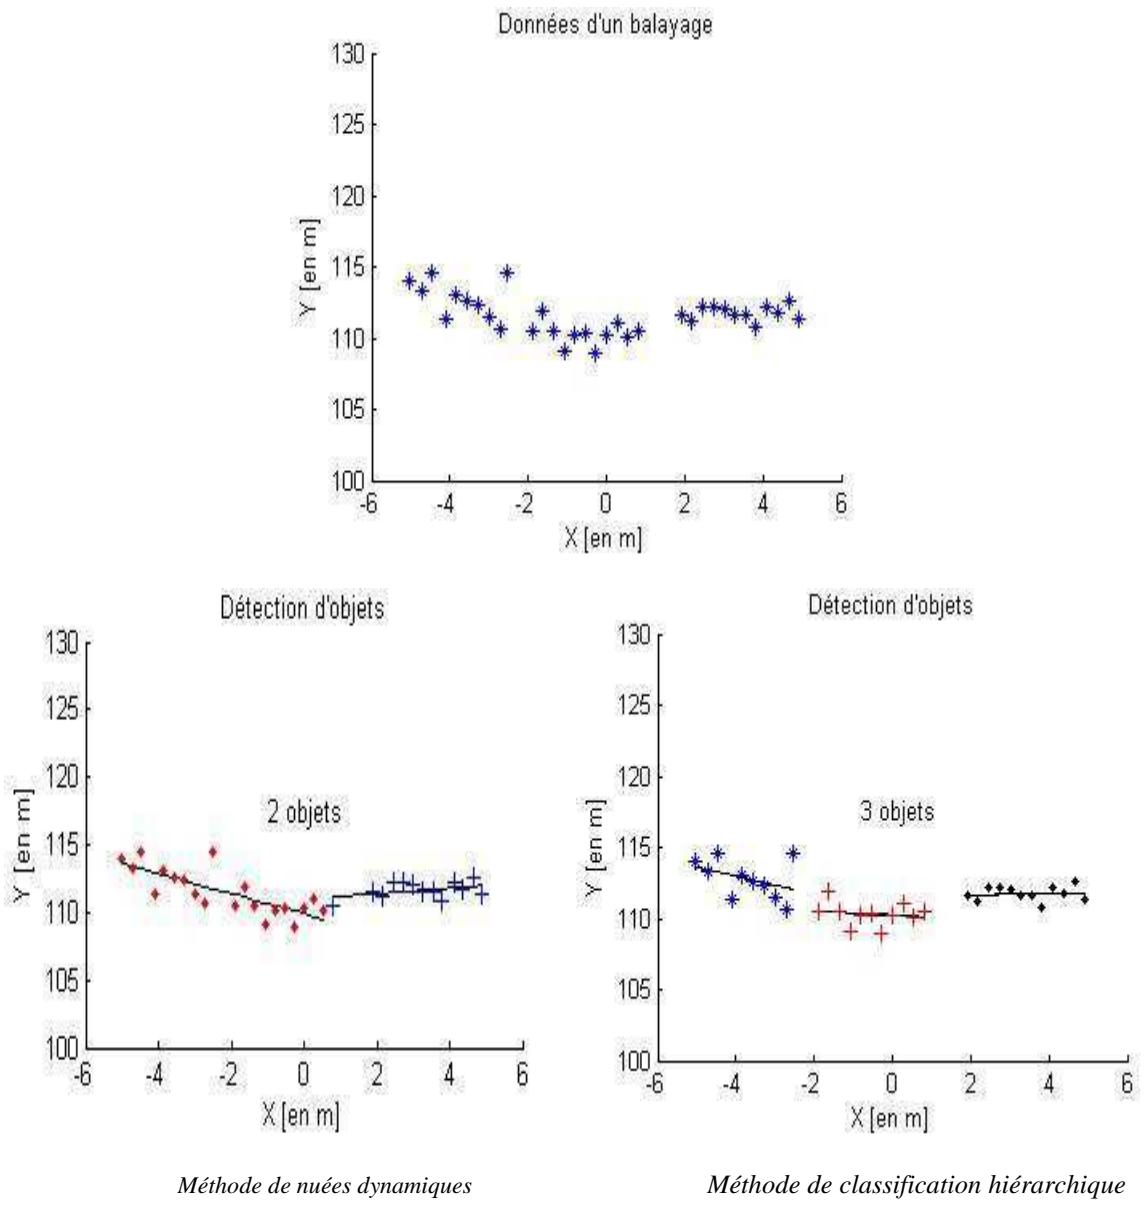


Figure 26: Exemple de détections par la variante de l'algorithme dérivé de la méthode séquentielle.

II.1.3.4 Comparaison des méthodes de détection présentées

Le problème d'extraction des objets de la scène sera d'autant plus difficile que les objets seront proches. En effet, pour tous les algorithmes testés, les seuils d'affectation apparaissent comme des distances de discrimination. Il devient donc difficile de séparer des objets lorsqu'ils sont proches. C'est la principale source d'erreur de ces algorithmes.

La figure 27 montre notamment le cas où l'une des deux méthodes ne permet pas de discriminer les 3 objets présents dans la scène parmi l'ensemble des mesures car une agrégation des points proches est réalisée (méthode des nuées dynamiques). L'autre méthode est plus robuste pour la discrimination d'objets proches.



Méthode de nuées dynamiques

Méthode de classification hiérarchique

Figure 27 : Exemple de détections dans un cas d'objets proches.

Précision

Nous avons testé ces méthodes de détection (méthode adaptée de la méthode de classification hiérarchique et la méthode dérivée de la méthode des nuées dynamiques et sa variante) sur des données simulées d'un capteur radar à balayage. Il s'agit d'une séquence de 10s composée de 200 acquisitions, où pour chaque balayage, le nombre d'objets présents est parfaitement connu. Les taux de détection (nombre d'objets détectés sur nombre d'objets réellement présents) obtenus par ces méthodes lors de l'expérimentation sont donnés dans le Tableau 1.

Méthode hiérarchique		Méthode séquentielle	
Algorithm 1	Algorithm 2 (variante)	Algorithm 3	Algorithm 4 (variante)
86%	98%	86.5%	95%

Tableau 1 : Taux de détection des algorithmes.

On constate bien que le taux de détection obtenu par la variante de la méthode hiérarchique (algorithme 2) est nettement meilleur que celui de la méthode hiérarchique classique. De la même manière, concernant la méthode séquentielle, il apparaît une réelle amélioration pour la variante. Cependant l'algorithme issu de la méthode hiérarchique (algorithme 2) demeure plus performant.

Temps d'exécution

Le Tableau 2 donne une comparaison des temps d'exécution des différents algorithmes testés. Ces temps d'exécution représentent une moyenne sur les 200 acquisitions. Les algorithmes sont implantés en MATLAB sur un processeur Intel Centrino à 2 GHz. L'algorithme 2, correspondant à la variante de la méthode séquentielle, apparaît comme le plus rapide.

Méthode Hiérarchique		Méthode séquentielle	
Algorithme 1	Algorithme 2 (Variante)	Algorithme 3	Algorithme 4 (Variante)
0.03s	0.031s	0.002s	5.10^{-4} s

Tableau 2 : Temps d'exécution moyen sur les acquisitions.

Après l'évaluation des méthodes de détection testées, il s'avère que la variante de la méthode séquentielle soit la plus performante lorsque l'on combine le pourcentage d'erreur de détection et la rapidité d'exécution. Même si la variante de la méthode hiérarchique commet moins d'erreur, le critère de temps est prépondérant dans l'optique d'une implantation temps réel de nos algorithmes. C'est donc cette méthode qui sera utilisée lors de l'étape de détection pour notre application dans ce chapitre et sur les données synthétiques.

Remarquons que dans le cas où il n'y a pas de chevauchement entre les mesures d'un balayage, il est plus facile d'appliquer une méthode de détection classique basée sur un *clustering* construit à partir de la distance entre les impacts successifs. La séparation des classes se fait alors par comparaison de la distance à un seuil. Si la distance est inférieure à ce seuil, la mesure est associée au *cluster* en cours. Dans le cas contraire, la mesure courante sera à l'origine d'une nouvelle classe. C'est cette méthode qui sera utilisée sur les données réelles.

II.1.4 Détection des objets dans des données réelles

Pour les données réelles, nous avons préféré mettre en œuvre une méthode de clustering basée sur la distance entre les impacts (un paragraphe dédié à cette problématique et à différentes méthodes existantes est proposé dans le chapitre III). La discrimination des classes de mesures représentant les objets de la scène (*clustering*) dans l'ensemble des mesures fournies lors d'un balayage se fera donc selon un critère de distance. Le principe est le regroupement de tous les impacts appartenant à un objet dans une classe à l'aide d'un critère de distance et d'un seuil de détection. Il existe un grand nombre de fonctions de distance permettant cette classification (Euclidienne, Minkowsky, Manhattan, Chebychev, Khi-square, Mahalanobis). Nous avons, pour des raisons de simplicité, retenu la distance euclidienne comme critère de distance, en incluant cependant la statistique du bruit en distance sur les distances capteur-objets. La méthode utilisée est basée sur l'affectation successive des mesures à la classe des mesures en formation, tant que la distance euclidienne entre

deux mesures successives est inférieure ou égale au seuil séquentiellement calculé. Lorsque la distance dépasse ce seuil, la mesure courante sera à l'origine d'une nouvelle classe et correspond donc à un nouvel objet. Le seuil est une simplification du critère de Borges (paragraphe III.4.1) en ne considérant que la classification de segments parallèles (ou quasi-parallèles) à l'axe des X :

$$seuil = \frac{\rho \cdot \alpha}{\sin(\theta + \alpha)} + 3 \cdot \sigma_\rho$$

où

ρ est la distance entre le capteur et l'impact sur l'objet visé,
 θ est l'angle du tir correspondant,
 α est la résolution angulaire,
 σ_ρ représente l'incertitude sur la mesure de distance.

A noter que cette méthode de classification est utilisée dans [Izri, 2004a] avec un seuil fixe calculé de manière heuristique.

La figure 28 montre les mesures correspondant à un balayage du capteur laser (IBEO). Il balaye l'environnement avec une résolution angulaire déterminée ($0,25^\circ$, $0,5^\circ$ ou 1°) avec une ouverture angulaire pouvant aller jusqu'à 270° . Ce capteur fournit des mesures en coordonnées polaires (ρ , θ) (cf. paragraphe I.5.4.1). Dans notre jeu de données, l'angle d'ouverture utilisée est de 160° avec une résolution angulaire de $0,25^\circ$. La fréquence d'acquisition est de 10Hz.

La figure 29 illustre les mesures provenant des objets mobiles (véhicules) de la scène. L'objectif est de trouver l'ensemble de mesures provenant des objets d'intérêt en appliquant la méthode de détection détaillée précédemment et de modéliser ces ensembles de mesures appartenant à chacun des objets par une forme géométrique (un rectangle). Cet ensemble de mesures est obtenu après avoir défini au préalable (ici par expertise) les bords de la route afin de ne conserver que les mesures qui sont situées dans une zone d'intérêt d'observation de part et d'autre du véhicule équipé du capteur. Il va de soi que des approches de détection de bords de route utilisant, par exemple, une caméra couplée à une reconnaissance des lignes au sol, ou encore des approches de géolocalisation par GPS, peuvent être envisagée.

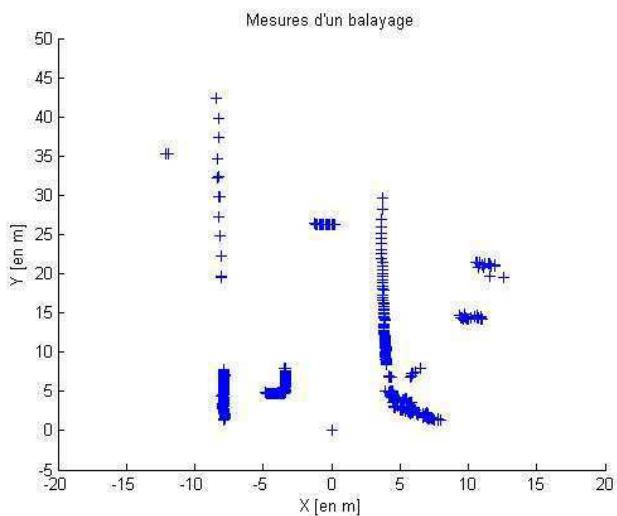


Figure 28 : Exemple des données réelles correspondant à un balayage.

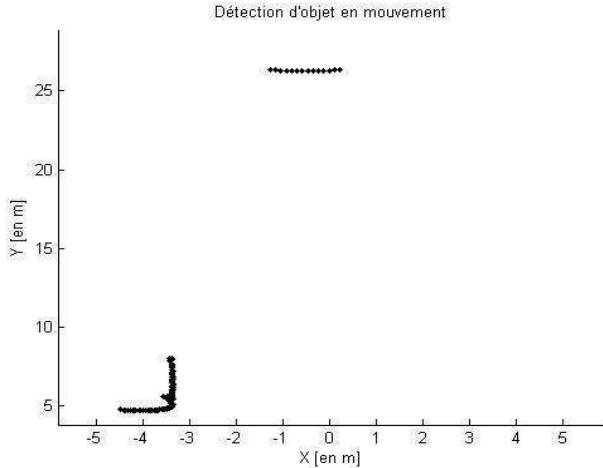


Figure 29 : Mesures correspondant aux objets mobiles de la figure 28.

Nous pouvons constater sur la figure 30 que les deux véhicules dans la scène (figure 28) ont été correctement détectés.

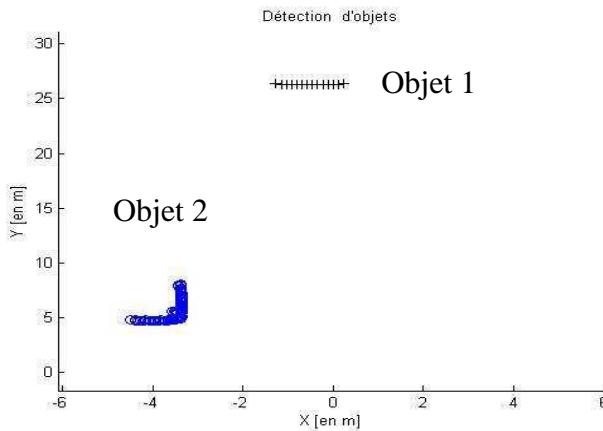


Figure 30: Résultats de détection obtenus par la méthode séquentielle.

II.2 Suivi d'objets en mouvement

Une fois l'étape de détection des objets présents dans la scène réalisée (*cf. figure 6*), il est ensuite nécessaire d'estimer les paramètres dynamiques de chacun de ces objets. Cette opération comporte deux étapes qui sont indissociables :

- une étape d'association temporelle qui permet de faire le lien entre l'objet suivi et les mesures disponibles à l'instant courant (objets détectés),
- cette association permet alors d'injecter dans le filtre de poursuite les mesures nécessaires à une correction efficace de l'état estimé (paramètres dynamiques).

Nous détaillons par la suite les principes du filtrage, en nous appuyant sur une modélisation d'état adaptée, en particulier en terme de mouvement. Le filtre ainsi construit permet d'assurer une détermination de la position prédictive de chaque véhicule, qui servira de base à l'étape d'association temporelle. Le filtre intègre alors les différentes mesures associées pour délivrer une estimation des paramètres dynamiques de chaque véhicule, de manière indépendante.

Nous allons tout d'abord présenter le principe du filtrage utilisé et nous déterminerons également les modèles de mouvements envisagés pour nos objets. C'est à l'issue de l'étape de prédiction du filtre qu'il sera possible de passer à la phase de mise en correspondance entre objets observés et les pistes. Cette phase d'association sera donc présentée après la phase de filtrage.

II.2.1 Filtrage

Les méthodes de filtrage ont été largement utilisées en localisation, navigation ou encore dans les problèmes de suivi. Le filtrage permet, en effet, d'estimer de façon récursive un processus stochastique à partir des mesures de son évolution. Il s'agit ici d'estimer les paramètres dynamiques des objets détectés et de les poursuivre dans la séquence. Pour cela, il convient d'utiliser un modèle *a priori* de mouvement et de modéliser les mesures issues des capteurs (fonctions de transfert, statistiques des bruits).

Dans le cas de modèle d'incertitudes gaussiens, la solution explicite du problème d'estimation, pour les systèmes linéaires, est le filtre de Kalman (FK) [Kalman, 1960], [Welch, 2004]. L'extension de ce filtre au cas des systèmes non-linéaires passe par une linéarisation des équations d'état qui conduisent au Filtre de Kalman Etendu (FKE) [Bar-Shalom, 1993].

Un filtre de Kalman est composé de deux étapes : une étape de prédiction qui exploite le modèle dynamique et une étape de correction qui utilise les mesures disponibles à l'instant courant. Lorsque plusieurs objets sont présents dans la scène, l'étape de correction ne peut se faire qu'après une phase d'association (décrise plus loin dans ce chapitre) pour mettre en correspondance les observations des objets de la scène avec les prédictions des différentes pistes déjà suivies.

Une explication détaillée des équations du filtre de Kalman Linéaire a été présentée dans le chapitre précédent.

II.2.1.1 Modèles de mouvement

On choisit ici de modéliser ce problème de suivi sous forme d'équations d'état que l'on résout par un filtre de Kalman. Dans l'optique d'une application d'assistance à la conduite, et plus particulièrement d'anticollision, nous avons opté pour l'utilisation de modèles de mouvements qui soient à la fois réaliste et robuste en terme de scénarios dynamiques possibles. Par la nature des capteurs mis en jeu, nous exploitons par la suite un modèle planaire de mouvement. Les objets sont supposés évoluer selon les équations de la cinématique (position, vitesse). Ce modèle simplifié de mouvement est toutefois suffisamment précis pour décrire l'évolution des objets de la scène sur autoroute avec des conditions de trafic fluide. A noter que pour ce modèle, l'accélération du véhicule se trouve rejetée dans les caractéristiques statistiques du bruit de modèle. L'ajout de la composante accélération ne pose toutefois aucun problème fondamental quant à l'approche développée.

Modèle cinématique (position/vitesse)

On définit donc le vecteur d'état d'un objet par $X = [x, v_x, y, v_y]^T$ avec x et y les coordonnées de l'objet suivi et v_x et v_y la vitesse en x (latérale) et en y (longitudinale) de l'objet.

Les équations linéaires de dynamique s'écrivent :

$$X_t = F_t X_{t-1} + W_{t-1}$$

Où A est la matrice de transition :

$$F_t = \begin{pmatrix} 1 & Te & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & Te \\ 0 & 0 & 0 & 1 \end{pmatrix}, \text{ } Te \text{ est la période d'échantillonnage.}$$

et $W_t = (0 \ \omega_t^x \ 0 \ \omega_t^y)$ est un bruit blanc gaussien de moyenne nulle et de matrice de covariance :

$$Q = \begin{pmatrix} \frac{T_e^3}{3} & \frac{T_e^2}{2} & 0 & 0 \\ \frac{T_e^2}{2} & T_e & 0 & 0 \\ 0 & 0 & \frac{T_e^3}{3} & \frac{T_e^2}{2} \\ 0 & 0 & \frac{T_e^2}{2} & T_e \end{pmatrix} \cdot \sigma^2, \text{ où } \sigma^2 \text{ est la variance des bruits } \omega_t^x \text{ et } \omega_t^y \text{ sur la vitesse.}$$

Le paramètre σ a été fixé à 1,7 m/Te afin de permettre une description réaliste de la dynamique d'un véhicule (cela autorise une accélération d'environ 0.8g).

Modèle d'observation

Le système est observé par un capteur télémétrique à balayage qui délivre des informations de position sur les véhicules présents dans la scène.

On modélise les observations de la manière suivante :

$$Z_t = \begin{pmatrix} x_t^{obs} \\ y_t^{obs} \end{pmatrix} = H X_t + V_t \text{ où } H = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix} \text{ est la matrice d'observation et } V_t \text{ est un bruit blanc gaussien de moyenne nulle et de covariance :}$$

$$R = \begin{bmatrix} \sigma_x^2 & \sigma_{xy}^2 \\ \sigma_{yx}^2 & \sigma_y^2 \end{bmatrix}.$$

La matrice de covariance du bruit d'observation en coordonnées cartésiennes est calculée en fonction des écarts-types (σ_ρ et σ_θ) des erreurs de mesures en coordonnées polaires. Malgré la perte de gaussienneté du bruit d'observation, nous avons choisi d'approcher la matrice de covariance en coordonnées cartésiennes de la manière suivante (par linéarisation) :

$$\sigma_x^2 = \sigma_\rho^2 \cos^2 \theta + \sigma_\theta^2 \rho^2 \sin^2 \theta, \quad \sigma_y^2 = \sigma_\rho^2 \sin^2 \theta + \sigma_\theta^2 \rho^2 \cos^2 \theta,$$

$$\sigma_{xy}^2 = \frac{1}{2} \sin 2\theta [\sigma_\rho^2 - \sigma_\theta^2 \rho^2] \text{ et } \sigma_{yx}^2 = \sigma_{xy}^2.$$

La nature physique du capteur a permis de modéliser σ_ρ et σ_θ constants, voire même σ_θ nul.

II.3 Association probabiliste de données

Cette étape est un préalable à l'étape de correction des paramètres dynamiques de chacun des objets suivis de la scène. L'objectif est, lors de chaque instant de mesure, d'associer les prédictions des objets suivis avec les nouvelles observations du capteur (issues de l'étape de détection). Plusieurs possibilités, qui procèdent de la gestion des pistes, sont alors envisageables :

- soit mettre à jour l'état des objets suivis, dans le cas où il y a eu association ;
- soit créer des nouvelles pistes pour les observations qui n'ont pas été associées ;
- soit supprimer les pistes périmées, *i.e.* n'ayant pas fait l'objet de nouvelles associations depuis un certain nombre de périodes d'échantillonnage.

Une des difficultés majeures dans cette problématique concerne la présence, dans la scène, d'objets multiples et parfois proches [Blackman, 1986]. L'étape d'association devient très délicate dans le cas où plusieurs objets sont à suivre. Plus elle est robuste (*i.e.* l'association est correcte), plus les pistes sont correctement suivies. Il s'agit de déterminer une probabilité d'association (d'où découle une probabilité de non association) entre les pistes et les nouvelles observations en utilisant la distance de Mahalanobis. Cette distance statistique dépend de l'innovation (erreur de prédiction sur la mesure), mais aussi de sa covariance. Un critère de décision basé sur cette distance est alors appliqué pour déterminer si une observation est candidate ou non à l'association (*i.e.* si elle est à l'origine de l'objet suivi ou non) et permettre ainsi la mise à jour des paramètres dynamiques de l'objet suivi.

II.3.1 Association temporelle

II.3.1.1 Critère d'association

Les mesures prédites par les filtres construits sur chaque hypothèse de piste sont comparées à l'ensemble des observations disponibles dans une étape de mise en correspondance afin de tenter d'associer chaque piste avec une ou plusieurs observation(s) disponible(s), voire même aucune.

Tout d'abord, les estimations de la position des objets en sortie du filtre de Kalman sont mises en correspondance avec les nouvelles observations obtenues en sortie de la phase de détection d'objets.

Cette mise en correspondance s'opère par un calcul d'une distance de Mahalanobis d_{ij} entre chaque piste prédite \hat{Z}_i ($i = 1, \dots, n$) et chaque objet détecté Z_j ($j = 1, \dots, m$). Cette distance normalisée fait appel à l'innovation délivrée par le filtre associé à chaque piste pour toutes les mesures disponibles :

$$d_{ij}^2(Z_j, \hat{Z}_i) = (Z_j(t) - \hat{Z}_i(t|t-1))^T S_i(t)^{-1} (Z_j(t) - \hat{Z}_i(t|t-1)),$$

où Z_j est le j -ème objet détecté, $\hat{Z}_i(t|t-1)$ est la mesure prédite de l'objet (ou piste) i et $S_i(t)$ est la matrice de covariance de l'innovation associée à la piste i pour la mesure j .

On montre aisément que l'innovation suit la statistique des bruits de mesure (ici gaussienne). La distance de Mahalanobis d_{ij} suit donc une loi du χ^2 à N_z degrés de liberté. L'observation j sera

alors considérée comme potentiellement issue de la piste i , et donc associée à cette piste, si la distance $d_{ij}^2(Z_j, \hat{Z}_i)$ est inférieure à un seuil prédéfini :

$$d_{ij}^2(Z_j, \hat{Z}_i) \leq \gamma.$$

Le seuil γ est déterminé à partir de la valeur de probabilité désirée pour que l'observation soit dans la région de validité selon un degré de liberté donné. A titre d'exemple, on présente figure 31 les régions de validité de quatre pistes. Ces régions sont représentées par des ellipsoïdes, centrées sur les positions prédites et dont les axes sont déterminés par la matrice de l'innovation $S_i(t)$ qui est directement délivrée par le filtre (cf. Chapitre I, Paragraphe I.3.2).

Le tableau ci-dessous donne la table des probabilités pour une mesure à deux dimensions (2D) et pour différentes valeurs du seuil γ .

$\gamma = g^2$	1 ($g = 1$)	4 ($g = 2$)	9 ($g = 3$)	9.2 ($g = 3.03$)	16 ($g = 4$)	25 ($g = 5$)
$N_z = 2$	0.393	0.865	0.989	0.99	0.9997	1

Tableau 3 : Valeur des probabilités de validité en fonction de δ pour $N_z=2$.

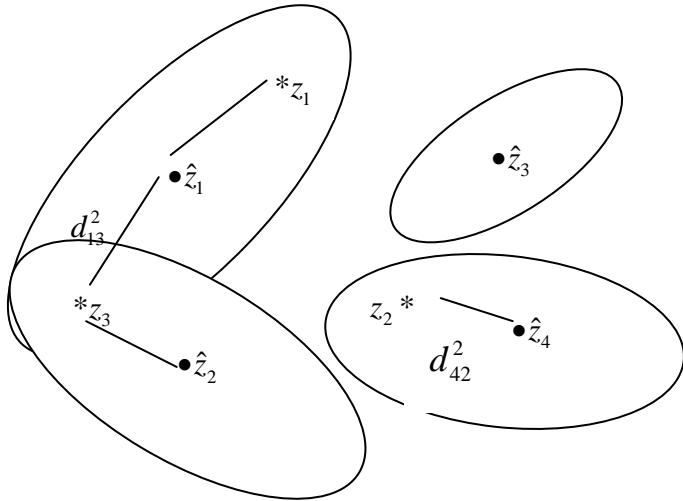


Figure 31 : Un exemple de représentation des régions de validité.

II.3.2 Gestion des pistes

Nous avons illustré sur la figure 32 les principales étapes de la gestion des pistes incluant la phase d'associations temporelles précédemment décrite. Une matrice d'hypothèses M , qui permettra d'opter pour la confirmation, la suppression ou la création des pistes, est alors construite. Elle met en relation les observations Z_j (colonne de la matrice) aux positions prédites \hat{Z}_i (ligne de la matrice). A l'instant t , l'ensemble des hypothèses d'association M^t est obtenu à partir de l'ensemble d'hypothèses M^{t-1} de l'instant $t-1$ et des observations à l'instant courant $Z(t) = (Z_1(t), Z_2(t), \dots, Z_{n_t}(t))$, où n_t est le nombre de d'observations à l'instant t .

Cette matrice représente donc l'association des nouvelles mesures aux pistes existantes où le nombre de lignes est donné par le nombre des pistes. Lorsqu'il n'y a pas de correspondance entre

une observation courante et une estimation alors la composante de la matrice est mise à 0, dans le cas contraire elle est mise à 1.

Prenons l'exemple de la figure 31 où quatre objets sont suivis et trois observations sont disponibles à l'instant t . La matrice M^t prend alors la forme suivante :

$$M^t = \begin{pmatrix} Z_1^t & Z_2^t & Z_3^t & \hat{Z}_1^t \\ 1 & 0 & 1 & \hat{Z}_1^t \\ 0 & 0 & 1 & \hat{Z}_2^t \\ 0 & 0 & 0 & \hat{Z}_3^t \\ 0 & 1 & 0 & \hat{Z}_4^t \end{pmatrix}$$

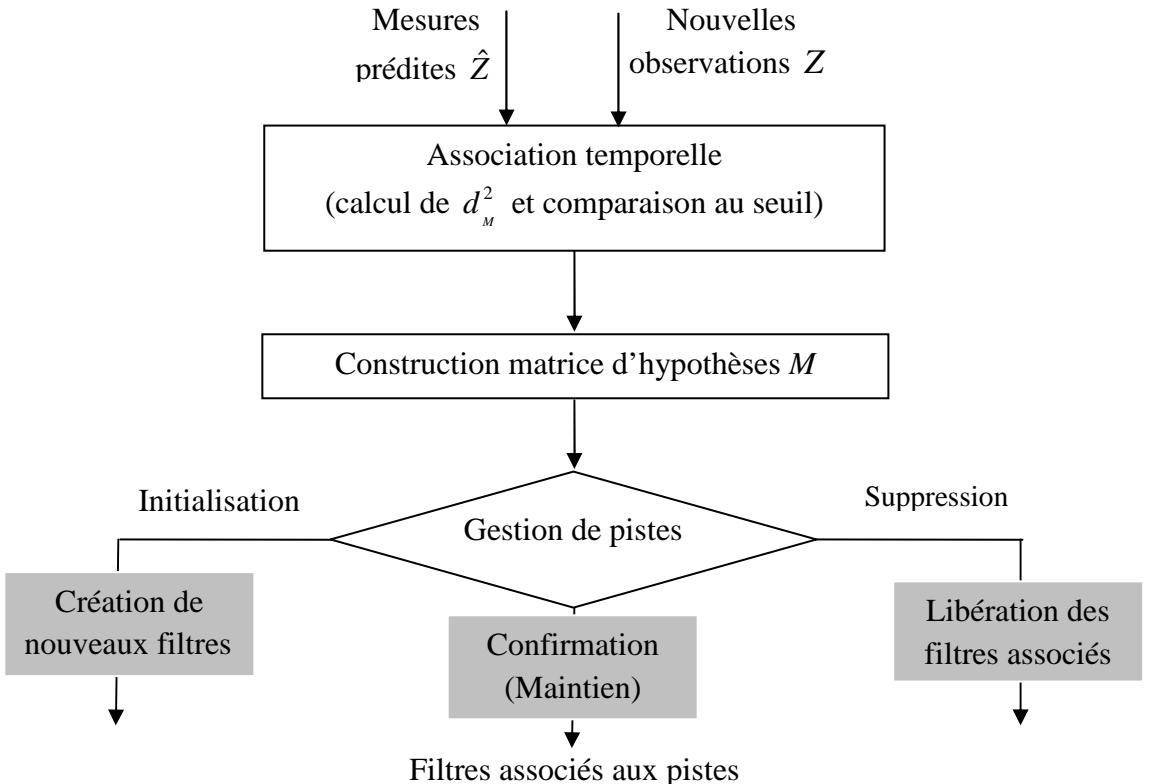


Figure 32 : Principe de la gestion des pistes.

Cette matrice est ensuite utilisée pour l'étape de gestion de pistes selon les règles suivantes :

- si aucune mise en correspondance n'est possible ($M^t = \underline{0}$), alors une nouvelle piste est créée pour chaque observation de Z .
- si pour une observation donnée aucune association n'est trouvée (une ligne de M^t ne contient que des 0), une nouvelle piste est également créée pour cette observation.
- la suppression d'une piste existante est possible si une ligne de M^t ne contient que des 0 pendant un nombre déterminé d'itérations. Le suivi d'une piste non utilisée pendant un certain laps de temps est ainsi arrêté et le filtre associé est libéré.
- dans le cas où plusieurs associations seraient possibles (une ligne de M^t contient plus d'un 1), alors 2 approches sont possibles :

- une association par une méthode classique du *Plus Proche Voisin* (PPV). l'association alors retenue est celle ayant la plus petite distance d_M . Les autres mesures non choisies participent à la création de nouvelles pistes.
- une association par une méthode PDA (Probabilistic Data Association), qui associe toutes les observations dans la région de validité à l'objet suivi. Cette méthode, que nous allons privilégier, est présentée dans le paragraphe suivant.

II.3.3 L'approche PDAF (Probabilistic Data Association Filter)

Sous l'hypothèse de séparabilité, nous avons choisi, pour chaque objet suivi, de mettre en œuvre un filtre PDA (Probabilistic Data Association) qui permet d'assurer l'étape d'association en intégrant les probabilités d'association entre les objets suivis et les objets observés par le capteur. Nous considérons que les régions de validité de chacune des pistes sont indépendantes, ainsi il devient possible de traiter toutes les associations, même multiples. Comme nous l'avons détaillé dans le chapitre I, l'approche PDAF prend en considération toutes les observations associées à l'objet suivi pour estimer son état. La mise à jour de l'état se fait, dans notre cas, par un filtre de Kalman.

Nous rappelons rapidement les principales étapes de la mise en œuvre de l'approche PDAF à notre problématique de suivi d'objets distribués :

1. Calcul des distances de Mahalanobis d_{ij}^2 entre la mesure prédictive \hat{Z}_i de la piste i (pour i variant de 1 à n_t , où n_t est le nombre de pistes à l'instant t) et les différentes observations candidates Z_j (pour j variant de 1 à m_t , le nombre d'observations disponibles à l'instant t) :

$$d_{ij}^2 = (Z_j(t) - \hat{Z}_i(t|t-1))^T S_{ij}^{-1}(t) (Z_j(t) - \hat{Z}_i(t|t-1))$$

où S_{ij} est la matrice de covariance de l'innovation de la piste i avec l'observation Z_j . Elle est définie par $S_{ij}(t) = H_t P_i(t|t-1) H_t^T + R_j(t)$ avec R_j est la matrice de covariance d'erreur sur l'observation Z_j qui est définie en fonction des incertitudes sur la distance ρ et l'angle θ (voir II.2.1.1)

On pose $e_{ij} = \exp(-d_{ij}^2/2)$.

2. Calcul de la probabilité qu'aucune observation ne corresponde à l'objet suivi :

$$\alpha_{i0} = \frac{b}{b + \sum_{j=1}^{m_t} e_{ij}}, \text{ avec } b = \lambda_{ij} \sqrt{\det(2\pi S)} \cdot \frac{1 - P_d P_G}{P_d},$$

où λ est la densité spatiale des fausses alarmes dans la région de validité de la piste i avec l'observation Z_j , P_G est un degré de confiance pour qu'une observation provenant réellement d'un objet soit effectivement candidate, P_d est la probabilité de détection, généralement fixée *a priori*. La valeur P_G correspond à la probabilité de validité (Tableau 3)

3. Calcul de la probabilité qu'une observation corresponde à l'objet suivi :

$$\alpha_{ij} = \frac{e_{ij}}{(b + \sum_{j=1}^{m_i} e_{ij})}.$$

4. Correction de l'état de l'objet suivi i à l'aide des équations suivantes :

$$\hat{X}_i(t|t) = \alpha_{i0} \hat{X}_i(t|t-1) + \sum_{j=1}^{m_i} \alpha_{ij}(t) \hat{X}_{ij}(t|t)$$

$$\text{avec : } \hat{X}_{ij}(t|t) = \hat{X}_i(t|t-1) + K_{ij}(t) \tilde{Z}_{ij}(t) ,$$

$$\text{où : } K_{ij}(t) = P_i(t|t-1) H_t^T S_{ij}^{-1}(t) \text{ et } \tilde{Z}_{ij}(t) = Z_j(t) - H_t \hat{X}_i(t|t-1)$$

$$P_i(t|t) = \alpha_{i0}(t) P_i(t|t-1) + (1 - \alpha_{i0}(t)) P_i^c(t|t) + \tilde{P}_i(t|t)$$

$$\text{avec : } P_i^c(t|t) = (I - K_i(t) H_t) P_i(t|t-1), \quad K_i(t) = \sum_{j=1}^{m_i} \alpha_{ij} K_{ij}(t)$$

$$\text{et } \tilde{P}_i(t|t) = \sum_{j=1}^{m_i} \alpha_{ij}(t) K_{ij}(t) \tilde{Z}_{ij}(t) \tilde{Z}_{ij}^T(t) K_{ij}^T(t) - \left(\sum_{j=1}^{m_i} \alpha_{ij}(t) K_{ij}(t) \tilde{Z}_{ij}(t) \right) \left(\sum_{j=1}^{m_i} \alpha_{ij}(t) K_{ij}(t) \tilde{Z}_{ij}(t) \right)^T$$

On constate que, dans le cas d'associations multiples, toutes les hypothèses sont prises en compte dans la mise à jour de l'état estimé.

II.4 Intégration du contexte

II.4.1 Position du problème

Comme on peut le constater sur les équations précédentes, le point central de la méthode PDAF est en particulier, la probabilité de détection de l'objet P_d . Cette probabilité est généralement introduite comme un paramètre que l'on calcule hors ligne. Dans le cas radar, pour lesquelles les méthodes PDAF ont été mises au point, P_d est généralement fournie par des abaques qui dépendent des conditions opératoires du radar.

Cette probabilité est donc directement liée au capteur, et doit pour cela être revue dans le cas de détection d'objets par télémètre laser à balayage. Une des principales difficultés repose sur la nature distribuée de la cible. L'aspect focalisé de la mesure rend également difficile le calcul de P_d . L'ensemble de ces points concourt à un pouvoir *a priori* envisager de détermination analytique de cette probabilité, qui ne peut de toute manière pas être considérée constante pour chaque objet et voire notamment en fonction des paramètres de l'objet.

Nous avons donc développé une approche qui permet justement d'intégrer le contexte pour déterminer de manière transparente cette probabilité de détection qui conditionne directement l'efficacité du processus de suivi.

L'intégration d'informations contextuelles comme par exemple, la taille de l'objet (aide à classifier les objets ; piétons, voiture, camion, etc.), la distance entre objet et le système de perception

(capteur(s)), les imprécisions sur les mesures, la nature de l'environnement, la capacité de fonctionnement du capteur, etc. sont des éléments qui rendent à renforcer le processus de suivi.

Peu de méthodes intègrent dans l'estimation la prise en compte du contexte dans lequel l'objet évolue. En effet, les méthodes très populaires d'association de données comme le PDA, JPDA ou le MHT supposent une connaissance *a priori* des caractéristiques du capteur.

Pour cela, nous avons trouvé dans les réseaux bayésiens le cadre mathématique qui permet d'envisager une telle problématique.

II.4.2 Apport des réseaux bayésiens à l'association de données

Afin d'améliorer les performances des filtres d'association (PDAF), nous proposons d'utiliser un réseau bayésien pour calculer l'évolution de la probabilité de détection de l'objet au cours du temps. Il s'agit alors de faire intervenir des informations *a priori* (dites contextuelles) qui serviront de point d'entrée à notre réseau bayésien pour déterminer une valeur, appelée détectabilité, pour chacune des pistes. Cette détectabilité sera intégrée dans les filtres d'associations (PDAF) en tant que probabilité de détection. Nous proposons par la suite une méthode de poursuite basée sur la mise en œuvre des réseaux bayésiens pour une approche PDA (BN-PDAF : Bayesian Network for Probabilistic Data Association Filter) [Jida, 2007b].

II.4.2.1 Rappels sur les réseaux bayésiens

Le formalisme des réseaux bayésiens semble représenter un outil adapté pour modéliser les dépendances entre entités de natures diverses. Il permet en particulier de modéliser et relier les informations contextuelles aux autres variables utilisées dans le système d'interprétation et de réaliser des inférences. Un autre avantage intéressant des réseaux bayésiens est la prise en compte de l'imperfection des informations et de leur propagation dans le raisonnement.

Un réseau bayésien est un graphe $G = (N, A)$ acyclique dirigé (figure 33) qui représente les connaissances sous forme de variables [Becker, 1999]. N est l'ensemble de noeuds du graphe et A est l'ensemble des arcs qui relient les noeuds du graphe. Pour l'utilisation que l'on fera des réseaux bayésiens, chaque noeud représentera une variable aléatoire qui prend ses valeurs dans un ensemble discret. Les arcs indiquent les causalités (dépendances) entre les variables du graphe. Une variable est alors définie par plusieurs états.

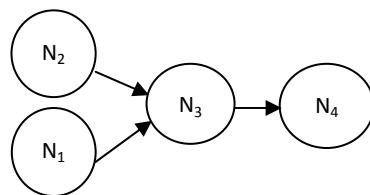


Figure 33 : Exemple d'une structure d'un réseau bayésien.

L'ensemble des distributions des probabilités définit les paramètres du réseau bayésien. Dans le cas discret, ces différentes probabilités se représentent sous forme de tables de probabilités pour chaque variable. Pour tous les noeuds sans parents, aussi appelés noeuds racines, (tels que N_1 et N_2 de la

figure 33), on définit une table des probabilités a priori (Tableau 4).

Etat ₁	Etat ₂
p_1	p_2

Tableau 4 : Table de probabilité (TP) *a priori* du noeud N_1 .

Pour tous les nœuds qui ont des parents (N_3 et N_4), appelés nœuds fils, on définit des probabilités conditionnelles. Pour le graphe pris en exemple, si on suppose que chaque variable a deux états, la table de probabilité conditionnelle de N_3 se représente comme sur le Tableau 5.

		N ₁	Etat ₁₁		Etat ₁₂				
			N ₂	Etat ₂₁	Etat ₂₂	Etat ₂₁	Etat ₂₂		
N ₃	Etat ₃₁	$p_{1 \rightarrow 1,1}$		$p_{1 \rightarrow 1,2}$		$p_{1 \rightarrow 2,1}$		$p_{1 \rightarrow 2,2}$	
	Etat ₃₂	$p_{2 \rightarrow 1,1}$		$p_{2 \rightarrow 1,2}$		$p_{2 \rightarrow 2,1}$		$p_{2 \rightarrow 2,2}$	

Tableau 5 : Table de probabilité conditionnelle (TPC) du nœud N_3 .

Dans le cas discret, ces tables de probabilités peuvent être traitées comme des matrices dont la forme et la taille dépendent du nombre des états parents et du nombre d'états du nœud lui-même.

L'inférence dans les réseaux bayésiens permet de prendre en compte n'importe quel état d'une variable d'observation (un événement) ainsi que d'effectuer la mise à jour des probabilités des autres variables. Cette mise à jour est obtenue par des calculs basés sur la théorie des probabilités qui est souvent utilisée pour la gestion d'événements incertains (i.e. le fait qu'une donnée peut être précise, mais que sa réalisation n'est pas sûre). Dans le formalisme probabiliste la mesure entre l'information disponible et les différentes hypothèses est représentée par une distribution de probabilité conditionnelle.

Le calcul des probabilités des états du nœud N_3 est ainsi obtenu à l'aide de la formule suivante :

$$p(N_3) = \sum_{m_i, n_j} p(N_3 | N_1 = m_i, N_2 = n_j) * p(N_1 = m_i) * p(N_2 = n_j)$$

où les $p(N_3 | N_1 = m_i, N_2 = n_j)$ correspondent aux probabilités conditionnelles, i.e. la probabilité de l'état du nœud N_3 connaissant les états des parents N_1 et N_2 (Tableau 5) et, et les $p(N_1 = m_i)$ sont des probabilités *a priori* des états du nœud racine N_1 .

Il existe une notion de dépendance et indépendance entre les nœuds du graphe. Par exemple, le nœud N_3 et les nœuds N_1 et N_2 sont dépendants. En revanche, les nœuds N_1 et N_2 sont indépendants. Ces notions de dépendance et d'indépendance sont expliquées dans [Becker, 1999].

Dans l'utilisation que nous allons faire des réseaux bayésiens, les paramètres (i.e. les probabilités conditionnelles) évoluent à chaque période d'échantillonnage. On est alors dans le cas de l'utilisation des réseaux bayésiens dynamiques. Ces réseaux sont une extension des réseaux bayésiens statiques. Ils sont utilisés pour modéliser les distributions de probabilités d'une manière temporelle. Une présentation détaillée de ces réseaux est donnée dans [Murphy, 2002]. Le lecteur

pourra également trouver en annexe (Annexe A) une présentation plus complète des réseaux bayésiens.

II.4.2.2 Détermination de la probabilité de détection par réseau bayésien

Nous construisons un réseau bayésien dont l'objectif est de prendre en compte des informations contextuelles afin de suivre l'évolution d'une grandeur, appelée *déTECTabilitÉ* (qui est équivalente à la probabilité de détection de la prédiction des pistes suivies). Il s'agit là de notre première approche pour l'utilisation des réseaux bayésiens dans ce contexte. Le réseau bayésien est donc relativement simple et prend en compte peu d'informations contextuelles [Jida, 2006], [Jida, 2007a]. Nous nous sommes donc limités à des informations contextuelles liées à l'objet suivi.

Après une étude de caractérisation des capteurs de type télémétrique [Rigo, 2004], nous pouvons remarquer que deux informations peuvent avoir une influence sur la détection des objets présents dans une scène : l'une, sa taille, provient directement de l'objet lui-même et l'autre, la distance au capteur, provient de son évolution et donc de l'estimation des ses caractéristiques dynamiques. Il s'agit donc de déterminer l'évolution de la déTECTabilitÉ (comprise entre 0 et 1) pour chacun des objets en fonction de sa taille mesurée et de sa distance prédictive.

Le réseau bayésien ainsi construit (figure 34) est donc composé de trois nœuds, chacun ayant deux états : Taille {grande, petite}, Distance {proche, loin} et DéTECTabilitÉ {détecté, non détecté} :

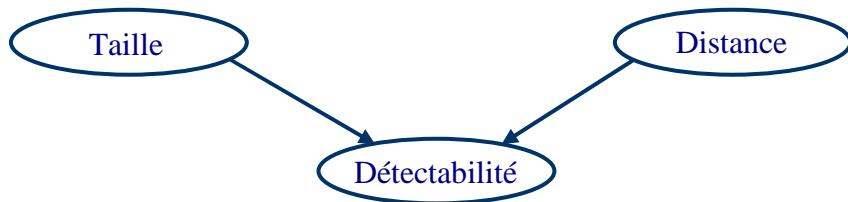


Figure 34 : Réseau bayésien utilisé pour l'intégration du contexte.

Nous sommes dans le cas d'un réseau bayésien dynamique : les tables de probabilités *a priori* des variables Taille et Distance sont mises à jour à chaque période d'échantillonnage et la table de probabilité *a priori* de la variable DéTECTabilitÉ est induite par inférence du réseau bayésien (figure 34). En revanche, la table de probabilités conditionnelles (Tableau 6) qui relie la variable DéTECTabilitÉ à ses nœuds parents est définie une fois pour toute. Dans l'exemple qui est présenté et que nous avons utilisé, elle est obtenue d'une manière qualitative par expertise.

		Taille	Petite		Grande	
		Distance	proche	loin	proche	loin
DéTECTabilitÉ	détecté	0.7	0.1	0.9	0.7	
	non détecté	0.3	0.9	0.1	0.3	

Tableau 6 : Table des probabilités conditionnelles du réseau bayésien.

La détermination de la variable DéTECTabilitÉ par le réseau bayésien permet d'introduire cette grandeur comme probabilité de détection P_d lors de l'étape d'association du PDAF, et ainsi de suivre son évolution au cours des estimations.

II.5 Expérimentations

Nous présentons ici les résultats obtenus par notre approche en détection et suivi d'objets multiples sur données synthétiques et réelles.

II.5.1 Données synthétiques

Nous présentons l'apport de notre approche BN-PDAF pour la poursuite multi-objets sur des données radar simulées. Les résultats obtenus sont comparés à ceux délivrés par un PDAF avec une probabilité de détection fixée *a priori* ($P_d = 1$) d'une part, et à ceux délivrés par un filtre de Kalman Linéaire (FKL), où l'observation la plus proche au sens de la distance de Mahalanobis est alors associée (principe de la méthode *Plus Proche Voisin* ou PPV).

La période Te d'échantillonnage des mesures est de 50 ms.

Pendant 10 s (soit 200 acquisitions), le véhicule porteur du capteur circule sur autoroute. Dans son environnement, il y a un véhicule (désigné par Véhicule 1, figure 36) circulant à contresens avec une vitesse relative de -50 km/h et une accélération nulle. Il y a aussi deux véhicules dans le même sens de circulation. L'un (nommé Véhicule 2, figure 36) est sur la même voie de circulation avec une vitesse relative de 50 km/h, une accélération de 1,5 m/s² et l'autre, (Véhicule 3, figure 36) circule sur la voie de droite avec une vitesse relative de 0 km/h et une accélération de 1 m/s².

II.5.1.1 Radar à balayage

Afin d'évaluer les performances de notre approche, nous utilisons des données synthétiques issues d'un simulateur radar, développé et présenté dans [Wahl, 1997], qui simule le fonctionnement d'un radar expérimental hyperfréquence à balayage PROMETHEUS PROCHIP France développé en 1994.

Ce simulateur fournit la valeur du premier écho « reçu » pour chaque angle de tir. Le pas de tir, l'angle de vision du capteur, les seuils de détection (portée du radar) et la durée du balayage sont paramétrables. Les données sont bruitées afin de simuler le comportement dynamique des véhicules sur route, notamment en terme de roulis et de tangage.

Ce capteur a une résolution angulaire de 0.14°, un angle d'ouverture de 6 degrés (-3°, +3°), un seuil bas de vision de 25 m et une portée maximale de 180 m. Il génère des données simulées en coordonnées polaires (ρ, θ). La figure 35 présente les mesures simulées obtenues selon le scénario schématisé.

On peut constater qu'il est possible d'obtenir des échos partiels provenant d'objets supposés occultés par un autre objet. Ce phénomène, dit de chevauchement (figure 35 à droite), se produit parce que seul l'écho le plus proche est gardé par le capteur et en raison du tangage du véhicule sur lequel est adapté le radar. Pour le simulateur, ces chevauchements sont obtenus par un bruit ajouté aux données. Ces phénomènes de chevauchement sont d'ailleurs à l'origine de l'attention particulière portée lors de l'étape de segmentation de ces données.

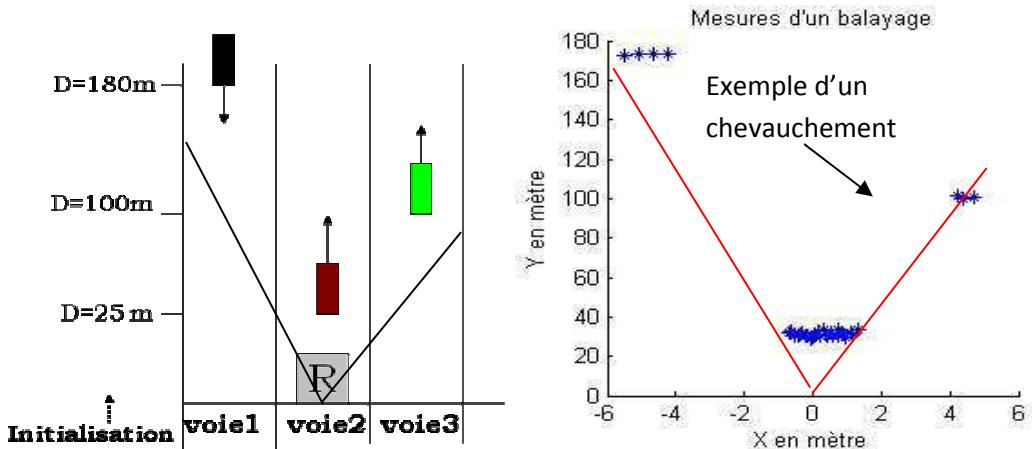


Figure 35 : Scénario (à gauche) et observations délivrées (avec chevauchement).

Les mesures délivrées par les capteurs s'appuient sur des phénomènes physiques. Elles sont entachées d'erreur que l'on modélise par un bruit additif de mesure. Ce bruit est ici supposé blanc et gaussien d'écart-type σ et de moyenne nulle.

La modélisation des bruits ajoutés aux données radar simulées est détaillée notamment dans [Wahl, 1997]. Cette modélisation se fait en deux étapes. Pour représenter le phénomène de chevauchement décrit plus haut, les extrémités des segments représentant l'arrière des véhicules présents sont d'abord bruitées. Puis chacune des coordonnées (x , y) des échos appartenant aux segments est à son tour bruitée pour simuler les erreurs en distance de ce type de capteur.

II.5.1.2 Résultats de détection et estimation

La figure 36 présente les positions estimées par l'approche proposée pour les trois véhicules. Lorsqu'un véhicule n'est plus observé, cas d'une occultation ou d'un défaut de détection (absence de détection ou détection unique pour des véhicules proches), le filtre attaché au véhicule considéré entre en prédiction pure (ces instants apparaissent en abscisse sur la figure). Lorsqu'un véhicule sort du champ de vision du capteur (cas du Véhicule 3 après l'instant 157), l'état n'est plus estimé.

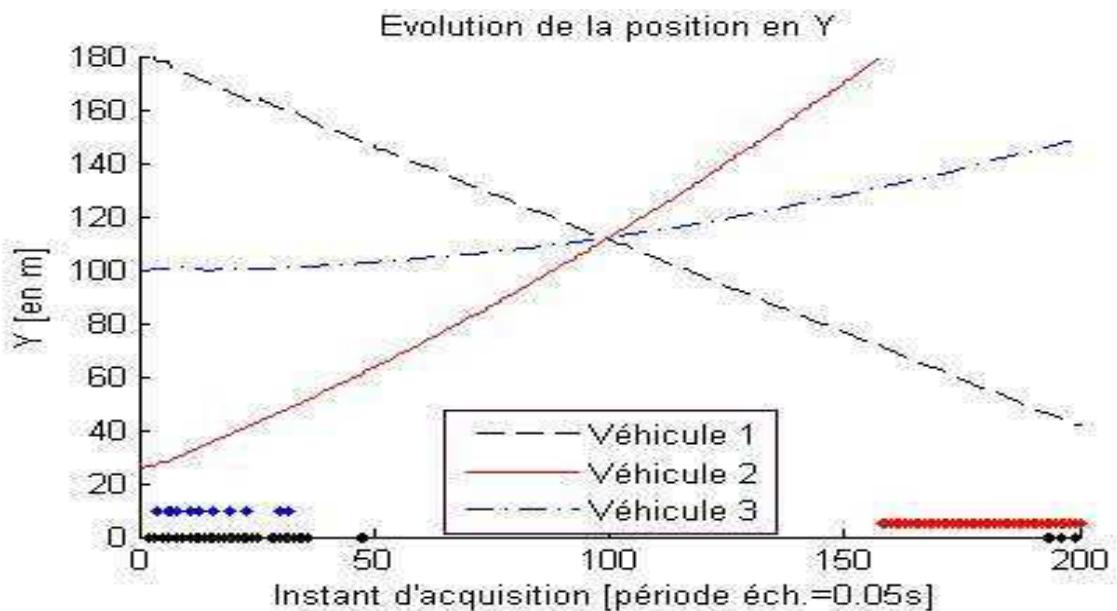


Figure 36 : Positions estimées par l'approche BN-PDAF.

La figure 37 montre l'évolution des estimations des vitesses relatives estimées selon la coordonnée Y (vitesse longitudinale) entre le véhicule porteur du capteur et le véhicule suivi. On peut remarquer que les estimations des véhicules sont cohérentes avec les valeurs de référence et que les accélérations sont bien prises en compte par le modèle.

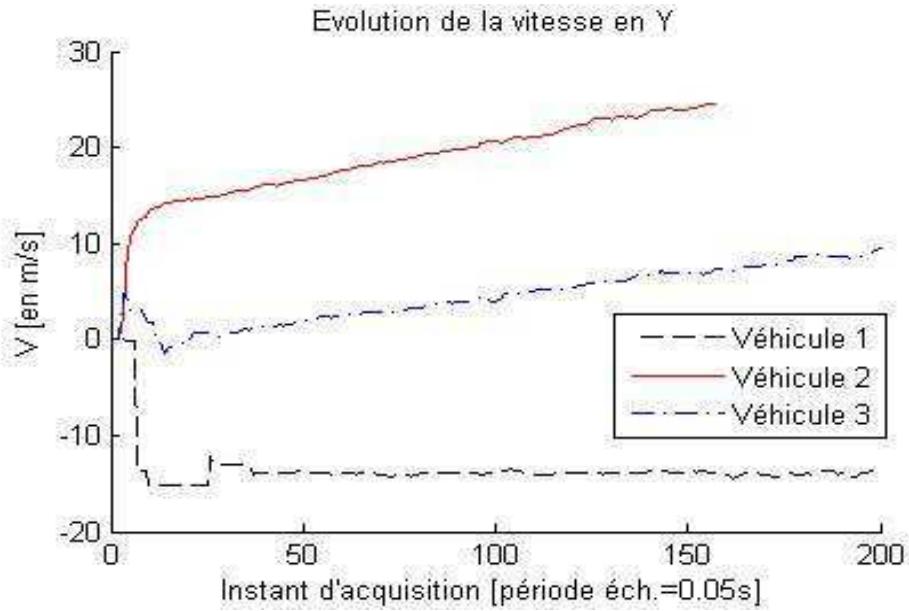


Figure 37 : Vitesses estimées par l'approche BN-PDAF.

L'évolution de la détectabilité obtenue par notre approche pour chacun des véhicules (*i.e.* la probabilité de détection en entrée du PDAF) est montrée sur la figure 38.

Pour réaliser l'inférence du réseau bayésien, deux informations contextuelles supplémentaires (la taille du véhicule et la distance de celui-ci au capteur) ont dû être estimées. Ces variables sont directement issues des mesures du capteur. La taille est déterminée par l'ensemble des points supposés appartenir à l'objet observé. En raison du bruit de mesure et de la résolution du capteur, il existe des variations sur cette grandeur (figure 39). La détermination de ce paramètre ('Taille') pourra, par exemple, provenir d'une étape de reconnaissance d'objets (pour déterminer s'il s'agit d'un véhicule léger, d'un camion, ...). Lorsque le filtre entre en prédition pure, cette taille reste constante et égale à la dernière valeur mesurée. La seconde variable (Distance) est obtenue par la mesure de la distance entre le centre de gravité des points appartenant au véhicule observé et le capteur. Ces deux grandeurs correspondent à des informations liées au contexte de la scène observée.

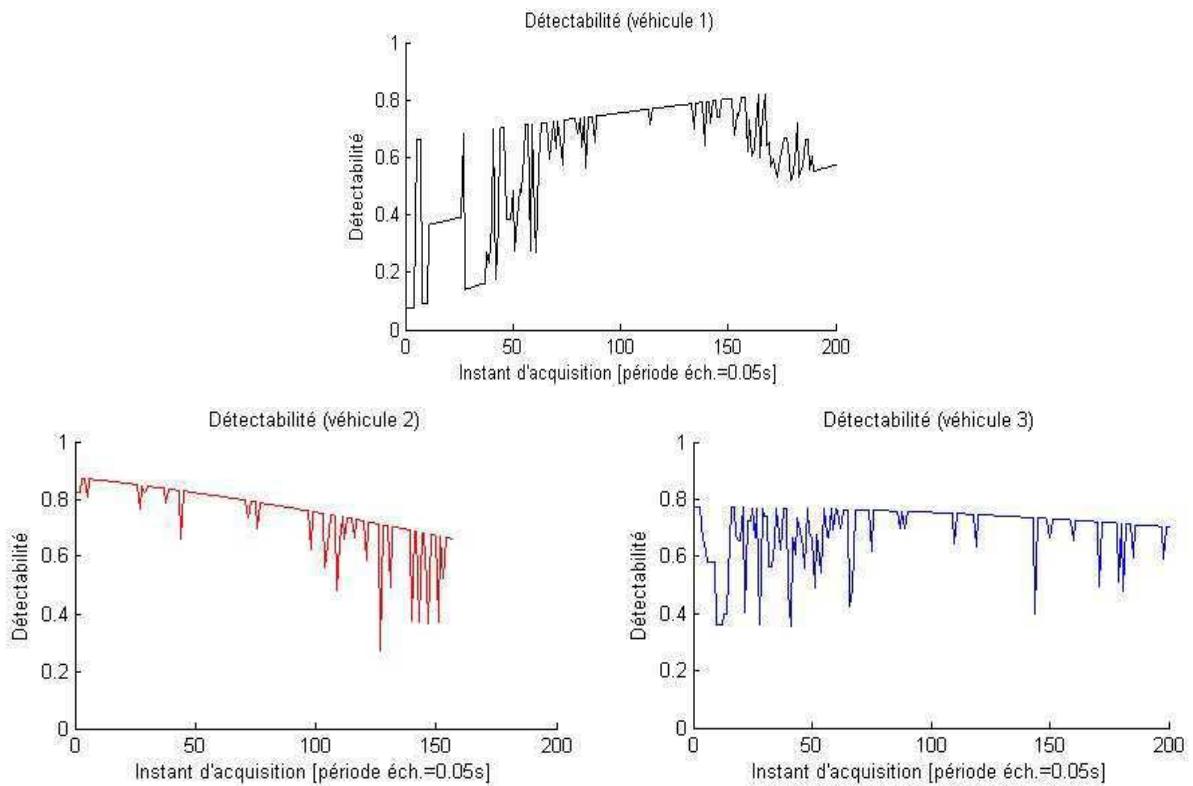


Figure 38 : Evolution de la détectabilité pour les 3 véhicules.

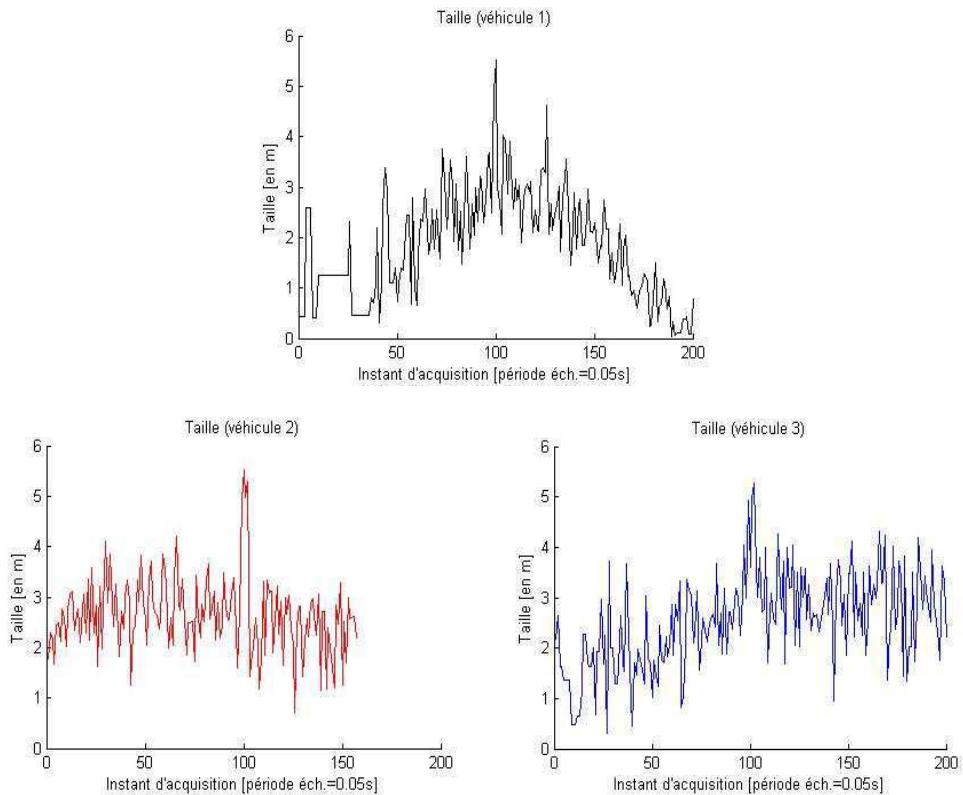


Figure 39 : Evolution des paramètres 'Taille' pour les 3 véhicules.

A titre de comparaison, nous présentons également les résultats de poursuite des trois véhicules délivrés par le filtre de Kalman Linéaire, avec association par la méthode du *Plus Proche Voisin* (FKL-PPV). Les erreurs sur les positions estimées longitudinales (en Y) pour les trois véhicules,

obtenues par les deux filtres (FKL-PPV et BN-PDAF), sont données sur les figure 40, figure 41 et figure 42.

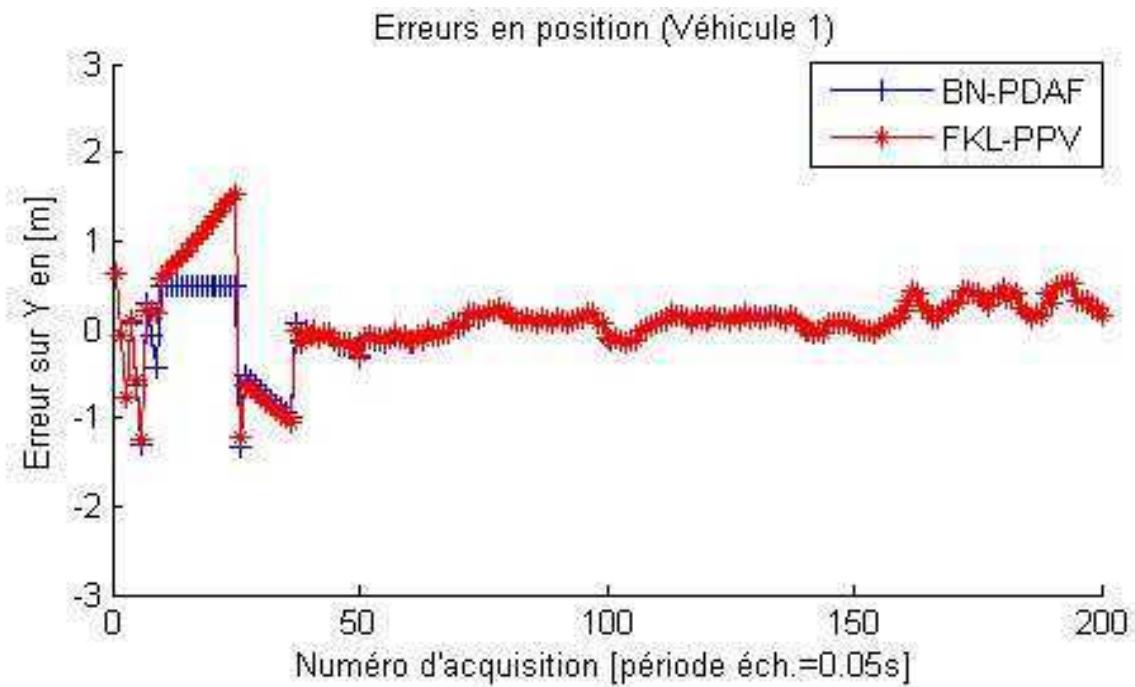


Figure 40 : Erreurs de positions estimées en Y (Véhicule 1).

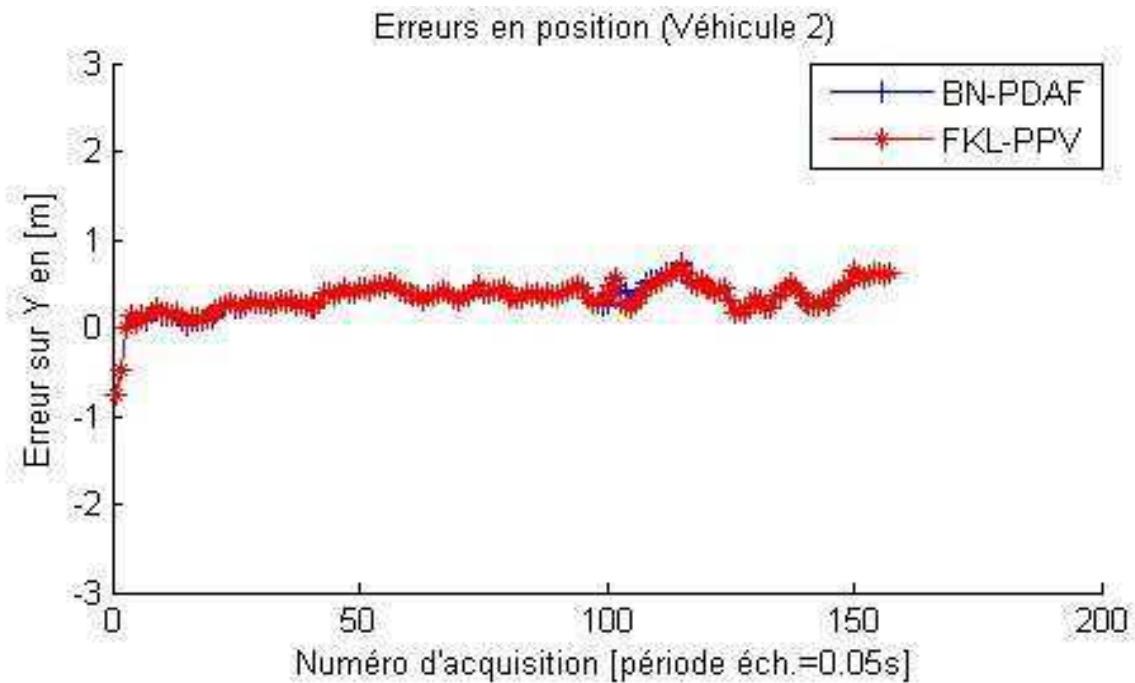


Figure 41 : Erreurs de positions estimées en Y (Véhicule 2).

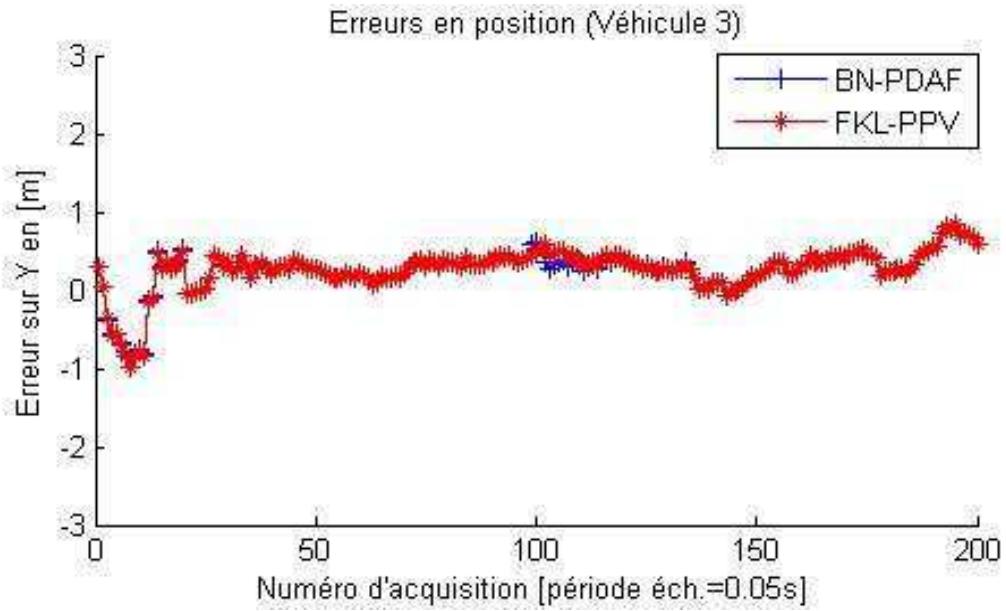


Figure 42 : Erreurs de positions estimées en Y (Véhicule 3).

Nous avons également appliqué le PDAF avec une probabilité de détection fixée *a priori* ($P_d = 1$). Les comparaisons des performances des trois méthodes sont données sous forme de tableaux où apparaissent les erreurs sur les positions en Y obtenues pour chacun des véhicules (Tableaux 7, 8 et 9).

	Véhicule 1	Véhicule 2	Véhicule 3
Moyenne	0.069	0.3450	0.2651
Ecart-type	0.3217	0.1804	0.2651

Tableau 7 : Erreurs sur la position Y avec le BN-PDAF.

	Véhicule 1	Véhicule 2	Véhicule 3
Moyenne	0.1163	0.3441	0.2663
Ecart-type	0.4174	0.1765	0.2728

Tableau 8 : Erreurs sur la position Y avec le FKL-PPV.

	Véhicule 1	Véhicule 2	Véhicule 3
Moyenne	0.1163	0.3469	0.2615
Ecart-type	0.4174	0.1782	0.2706

Tableau 9 : Erreurs sur la position Y avec le PDAF ($P_d = 1$).

Comme on peut le constater, les résultats obtenus sur cette simulation par l'approche proposée sont encourageants car ils permettent de montrer l'apport de la méthode dans le cas où des problèmes de détection se posent (cas du Véhicule 1). En effet, par la configuration de la scène, le Véhicule 1 se trouve pour certains instants en limite du champ de vision du capteur et pour d'autres dans une situation d'agrégation (proximité du Véhicule 2). Pour le véhicule 2, la méthode proposée ne permet pas une amélioration des résultats. Pour ce véhicule, les mauvaises détections sont très faibles (on a alors P_d proche de 1). Le calcul de P_d par notre approche montre une diminution de P_d pour ce véhicule (*cf.* figure 38). C'est sur ce point que la méthode d'estimation de P_d doit être améliorée.

II.5.2 Résultats sur données réelles (capteur IBEO)

Nous présentons ici les résultats sur de données réelles délivrées par un capteur IBEO laser à balayage à l'école des Mines de Paris lors d'un acquisition par le logiciel RTMaps. Le contexte de l'expérimentation est le suivant : le capteur est monté sur un véhicule mobile dans un contexte proche du contexte autoroutier (une ligne droite, une seule voie de circulation) avec deux véhicules dans la scène dont un qui entre et sort du champ de vision du capteur, qui double et se rabat.

La modélisation des bruits de mesures exploite les caractéristiques constructeurs. Ces bruits sont supposés gaussiens de moyenne nulle et d'écart-type σ . Les mesures du télémètre sont délivrées en coordonnées polaires (ρ, θ) . Selon les données constructeurs, l'écart-type σ_ρ sur la distance ρ est 1 cm quelle que soit la distance. Cette grandeur a été vérifiée expérimentalement. L'erreur angulaire est donnée nulle par le constructeur ($\sigma_\theta=0$). Toutefois, par souci de réalisme, nous l'avons modélisé comme un bruit très faible d'écart-type $\sigma_\theta=10^{-3}$ rad.

Les résultats de la figure 43 et de la figure 44 présentent l'estimation des positions (en coordonnées Y) et des vitesses relatives (en m/s). Les évaluations des probabilités des détectabilités des véhicules sont illustrées sur la figure 45.

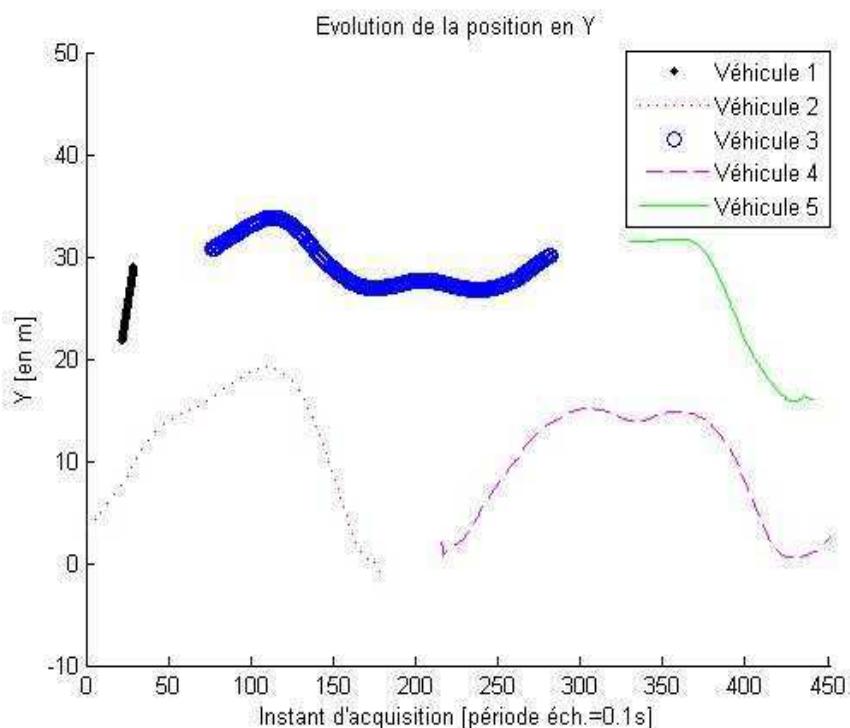


Figure 43 : Positions estimées des véhicules à l'avant du véhicule porteur lors de l'expérimentation.

On constate sur la figure 43 que les véhicules apparaissent dans la scène sous formes de deux pistes (piste 1 et piste 2). Au début de l'expérimentation, le véhicule le plus éloigné accélère mais disparaît du champ de vision car il est masqué par l'autre véhicule. L'algorithme de suivi détruit bien, à cette occasion, la piste correspondante. Le véhicule le plus proche accélère (masque l'autre véhicule) puis décélère pour finir par sortir du champ de vision en se faisant doubler par la droite par le véhicule équipé du capteur. La piste 3 (véhicule 3 correspondant au véhicule 1) apparaît alors lorsque le véhicule proche libère le champ de vision et permet d'observer à nouveau l'autre véhicule. La piste 4 (véhicule 4) apparaît lorsqu'un véhicule, correspondant au véhicule 2 sorti auparavant, entre à

nouveau dans le champ de vision avec une vitesse de ce véhicule très changeante selon l'estimation de notre algorithme (figure 44) pour finir par masquer à nouveau le second véhicule. Ce véhicule devient encore une fois visible (piste 5 = véhicule 5) lorsque le véhicule le plus proche libère le champ de vision de ce véhicule. Dans ce scénario, on voit que le suivi s'effectue correctement pour les deux véhicules. Cependant quelques paramètres ne semblent pas estimés correctement (on peut voir par exemple la position longitudinale du véhicule 1)

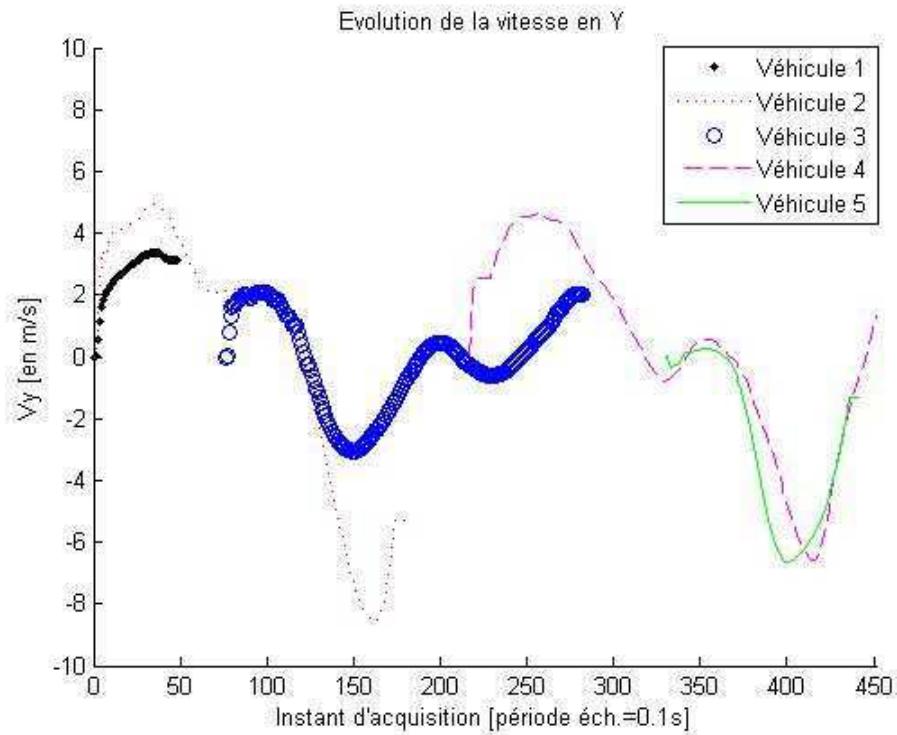


Figure 44 : Vitesses estimées des véhicules à l'avant du capteur lors de l'expérimentation.

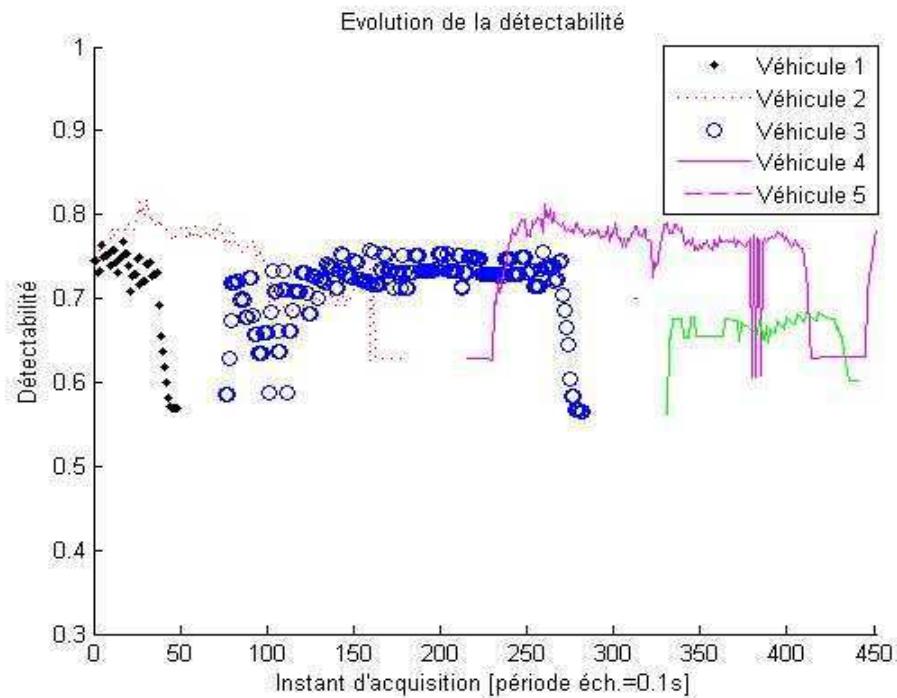


Figure 45 : Evaluation des probabilités des détectabilités des véhicules à l'avant du capteur.

On peut voir sur la figure 45 l'évolution de la détectabilité (que l'on intègre comme la probabilité de détection dans notre algorithme PDA) qui évolue relativement peu puisque les objets semblent avoir une taille assez grande, la résolution angulaire est faible et les objets se trouvent en moyenne relativement proche du capteur (le nombre d'impacts par véhicule est suffisant pour une détection correcte). Les évolutions des estimations en position et vitesse (en Y) obtenues par l'approche probabiliste qui se base sur les réseaux bayésiens montrent cependant des résultats de suivi encourageant, pour une première approche (les paramètres dynamiques sont assez correctement déterminés avec l'algorithme PDA et l'intégration du contexte capteur/objet par le réseau bayésien).

II.5.3 Résultats sur données réelles (capteur SICK LMS)

Les données utilisées ont été enregistrées par l'UTC de Compiègne en zone urbaine. Pour ce scénario d'expérimentation d'une durée d'environ 15s (1200 acquisitions précisément), le télémètre LMS 200 (version outdoor) est monté sur une voiture circulant en ville, un véhicule est en permanence à l'avant de celle-ci porteur et un autre apparaît sur la voie opposée. La figure 46 montre une image de cette scène ainsi que les données télémétriques correspondantes obtenues avec une résolution angulaire de 1° et un champ de vision angulaire de 180° . Les mesures du télémètre nous donnent les coordonnées des objets présents dans la scène (véhicule en mouvement et décor). Nous avons également illustré les limitations du champ de vision de la caméra par recalage (les impacts en rouge sont dans le champ de la caméra, les autres hors champs)

La fréquence d'échantillonnage des mesures est de 75 Hz (soit une période $\approx 13,3\text{ms}$).

Les modèles des bruits du capteur LMS sont ceux présentés dans le paragraphe I.5.4.2.

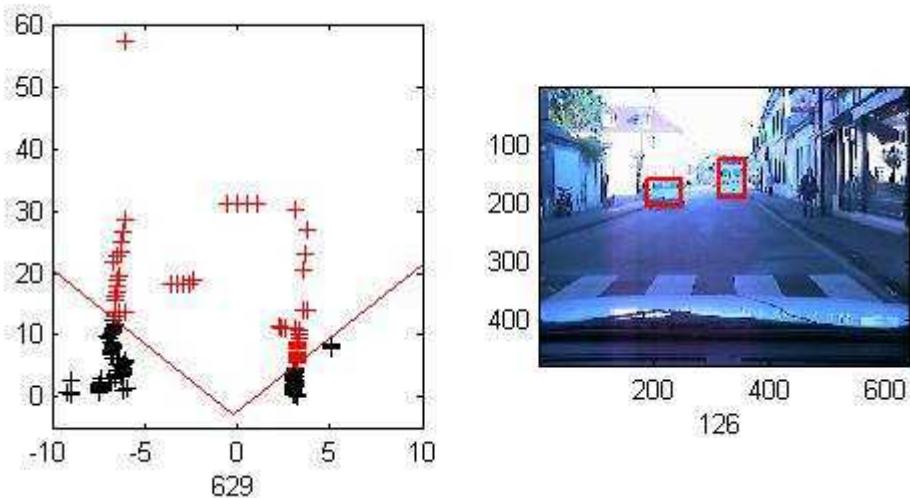


Figure 46 : Données du télémètre laser (à droite) pour des données urbaines (image de gauche).

Les résultats des (figure 47, figure 48) et des (figure 49, figure 50) présentent les évolutions des positions latérales et longitudinales estimées des véhicules ainsi que les vitesses correspondants en m/s. On constate sur la figure 47 les mouvements des deux véhicules, avec l'apparition du second véhicule qui se rapproche. Le premier véhicule ralentit et se rapproche du capteur avec un léger mouvement latéral, dû avant tout à la voie de circulation (le véhicule aborde un rond point).

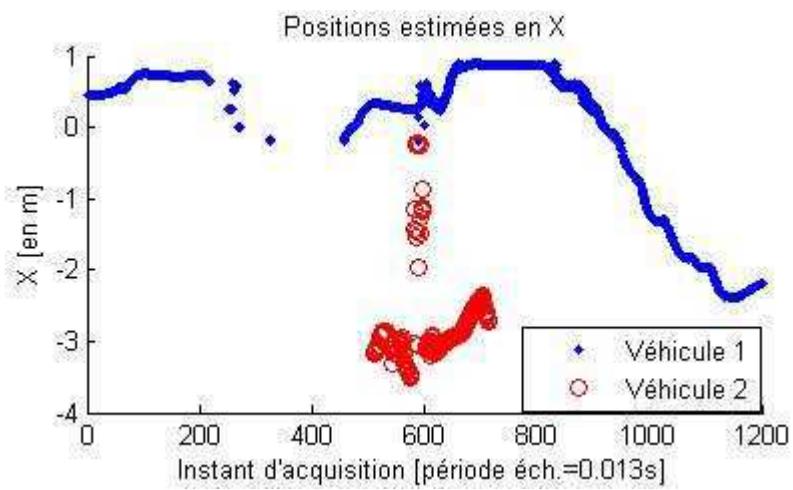


Figure 47 : Positions estimées des véhicules sur X.

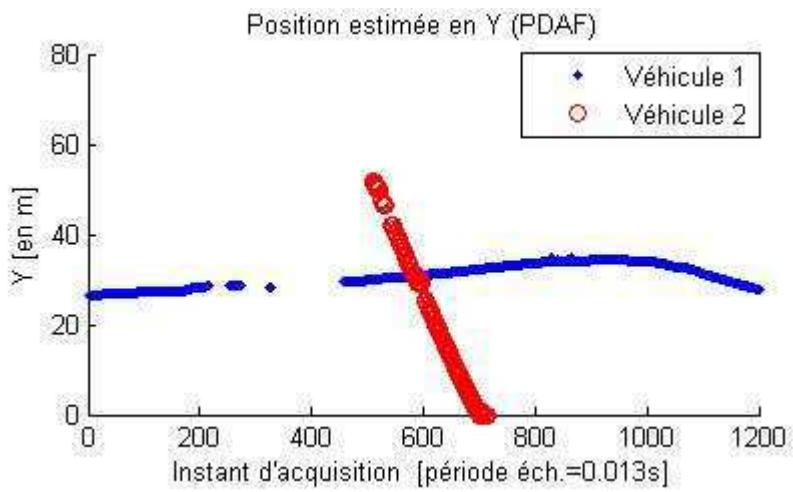


Figure 48 : Positions estimées des véhicules sur Y.

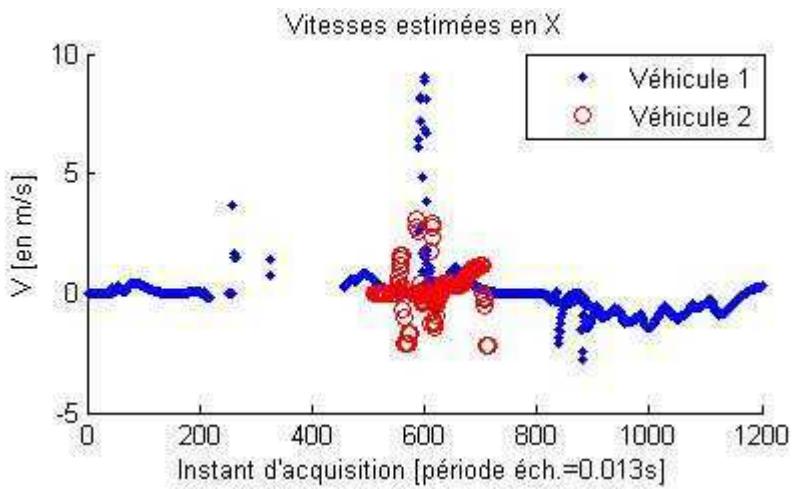


Figure 49 : Vitesses estimées des véhicules sur X.

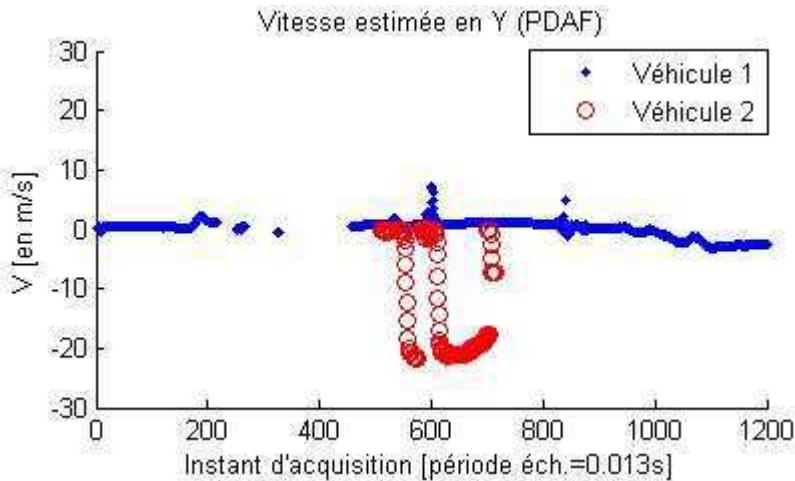


Figure 50 : Vitesses estimées des véhicules sur Y.

Les figures précédentes (figure 47, figure 48, figure 49 et figure 50) nous montrent que malgré la simplicité du scénario et des données traitées, il y a de nombreuses erreurs de détection. Mais dans ce cas, ce n'est pas le fait de l'algorithme de détection, mais plutôt d'un manque de données (incertitudes des mesures) provenant soit d'une mauvaise réflexion sur les surfaces des véhicules, soit plus sûrement ici, du tangage du véhicule porteur. Au regard d'une analyse des images fournies, et malgré les données manquantes entraînant la destruction des pistes et le passage en prédition du filtre d'estimation, l'approche proposée permet un bon suivi des véhicules.

Nous proposons sur la figure 51 l'évolution des tailles mesurées des véhicules puisque dans ces résultats, cette variable est estimée et c'est cette estimation qui est entrée dans le réseau bayésien (cf. figure 34). On voit cependant que cette détection entraîne de fortes variations des tailles, lorsque les véhicules sont détectés. Sur la figure 52, nous proposons l'évolution de la probabilité de détection. Comme les variations en distance du véhicule 1 sont relativement faibles (l'écart en distance reste sensiblement le même), on voit bien que la probabilité de détection varie essentiellement en fonction de la seule variable Taille. Par contre, pour le second véhicule qui s'approche, la probabilité de détection augmente en lien avec la diminution de la Distance. Les probabilités de détection des véhicules sont obtenues par les réseaux bayésiens.

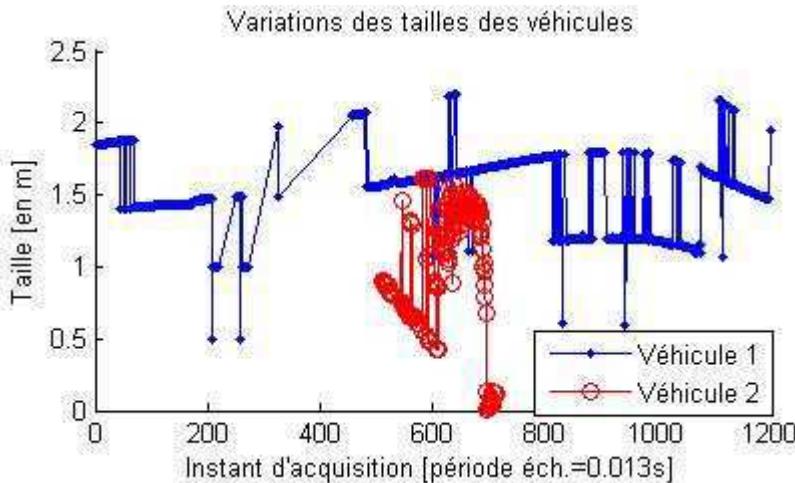


Figure 51 : Tailles des véhicules mesurées.

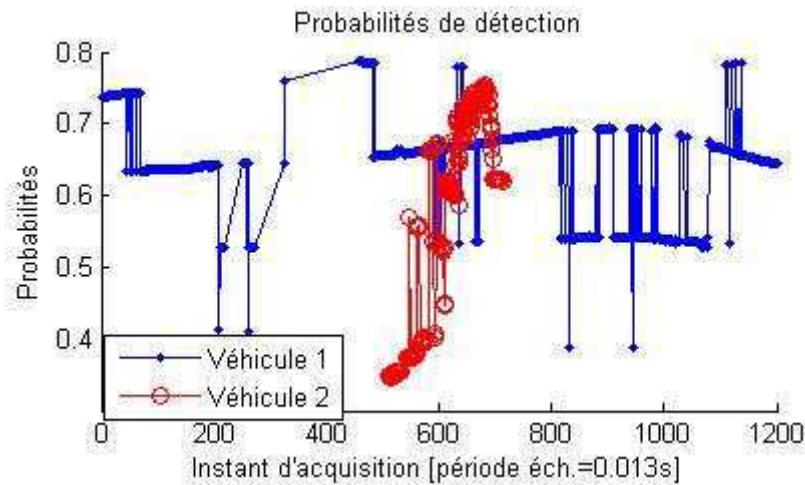


Figure 52 : Probabilités de détection des véhicules.

II.6 Conclusion

Nous avons présenté dans ce chapitre une méthode qui permet d'intégrer le contexte capteur/objet dans le processus d'association/suivi. Cette approche a notamment été développée dans le cadre du projet Ravioli (Radar, Vision Oriental, Lidar) avec un souci principal de proposer une méthode robuste et ayant des performances proches du temps réel.

Nous avons insisté sur deux éléments clés de l'approche proposée :

- La détection qui permet d'extraire les objets présents dans la scène. Cette étape fait appel à une méthode relativement fruste pour respecter les contraintes expérimentales mais aussi le type de capteur utilisé.
- L'association de données pour laquelle on propose de calculer de manière dynamique les probabilités de détection associées à chaque objet.

L'approche proposée a été appliquée sur données synthétiques et réelles. Elle a montré des gains intéressants en terme d'amélioration du processus d'estimation et suivi.

Chapitre III

Détection à partir de données télémétriques

Nous avons présenté dans le chapitre précédent les premiers résultats obtenus sur la prise en compte du contexte capteur-objet dans le processus d'association-suivi sur des données télémétriques. Nous avons notamment montré l'apport de la mise en œuvre des réseaux bayésiens pour l'estimation dynamique de la probabilité de détection des objets, qui est un point central dans l'utilisation des approches PDA. Cela nous a, en particulier, permis d'améliorer à terme les performances en estimation du filtre associé.

Pour aller plus loin dans la prise en compte de l'environnement du véhicule, il est important d'intégrer, non seulement les liens capteur-objet, mais également les interdépendances dont les objets font preuves vis-à-vis des mesures (notamment les phénomènes d'occultation qui influent grandement sur la probabilité réelle de détection d'un objet). Toutefois, avant d'introduire l'ensemble de ces considérations dans le chapitre IV, il est nécessaire de revenir sur le processus de détection d'objet à proprement parler car il conditionne directement les variations de la probabilité de détection à chaque instant.

Dans ce chapitre, après avoir posé le problème de la détection dans un cadre général, nous étudions son extension pour des objets spatialement distribués observés par un capteur télémétrique. Nous proposons en particulier une méthode de détection (au sens large) d'objets plus adaptée aux spécificités applicatives de l'étude, *i.e.* des véhicules en mouvement sur secteur autoroutier. La particularité de cette méthode est d'exploiter des invariants géométriques de la scène, évitant de cette façon une détermination de valeur de seuil basée sur les distances inter-impacts, lors de l'étape de segmentation. Après avoir comparé les performances de cette nouvelle méthode avec des algorithmes couramment utilisés, nous caractérisons cet algorithme en fonction de divers paramètres pouvant influer sur ses performances. Des résultats sont également présentés sur des données réelles fournies par l'Ecole Nationale Supérieure des Mines de Paris, obtenues grâce au logiciel d'acquisition multicapteurs RTMaps de la société INTEMPORA.

III.1 Position générale du problème de détection

Comme nous l'avons présenté dans le chapitre précédent, notre intérêt se porte sur le suivi d'objets (ou cibles) multiples observés par un système de perception centré autour d'un capteur actif. Sur la figure 53, nous présentons la chaîne des traitements et les différentes étapes qui permettent de passer de l'objet observé renvoyant une énergie, elle-même reçue par le capteur qui la restitue sous forme de signal, pour enfin la convertir en mesures. Ces mesures alimentent le processus de suivi de manière à retrouver les paramètres dynamiques de l'objet à suivre.

Si un objet à suivre est dans le champ de vision du capteur, une partie des mesures proviennent vraisemblablement de cet objet et on dira alors qu'il est observé. On peut envisager de suivre le (ou les) objet(s) présent(s) dans une scène en utilisant les mesures brutes. En effet, pour certains capteurs et dans une configuration d'environnement d'observation grande, chacune des mesures peut ne correspondre qu'à un seul objet. C'est le cas, par exemple, de la surveillance de zone étendue par un radar. Dans le cas où plusieurs mesures proviennent du même objet (c'est le cas dans notre problématique), suivre chacune des mesures indépendamment des objets est possible. Pour faire le parallèle avec l'image, cela revient à utiliser le pixel comme primitive. Cependant, le suivi des mesures brutes est peu envisageable pour différentes raisons :

- le contenu informationnel de chacune des mesures est faible. La détermination des caractéristiques dynamiques et l'association entre les mesures et leurs prédictions sont donc très difficiles ;
- même si le nombre de mesures est limité, le nombre de pistes à suivre entraîne un coût calculatoire élevé.
- l'objectif d'un processus de suivi est de retrouver les paramètres dynamiques des objets de la scène. La correspondance entre mesures et objets est donc de toute façon nécessaire.

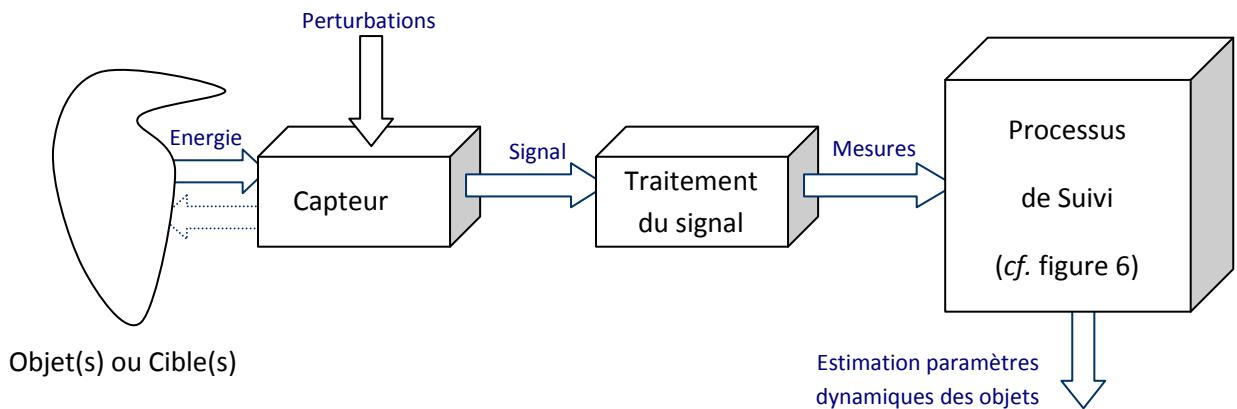


Figure 53: Chaîne de traitements d'un algorithme de suivi.

Pour ces raisons, il est préférable d'extraire des observations (ou primitives) pertinentes provenant des différents objets d'intérêt de la scène à partir des mesures fournies par le système de perception. Cette étape est communément appelée « détection ». Nous allons rappeler les principales phases de la détection, en précisant qu'elles n'apparaissent pas toujours de manière explicite ou qu'elles sont parfois imbriquées les unes dans les autres :

- le *clustering* (ou phase de groupement) : D'une manière générale, on entend par *clustering*, la division d'un ensemble de données en sous-ensembles (appelés *clusters*) formés de données ayant un caractère commun. Pour les données télémétriques, il s'agira avant tout d'essayer de regrouper des impacts appartenant à un même objet. Cette étape fera l'objet d'une présentation plus détaillée dans ce chapitre.
- la segmentation : Au regard des objets que l'on cherche principalement à suivre (*i.e.* des véhicules), il semble qu'une modélisation polygonale de l'environnement soit adaptée. Les parties d'un objet visibles par le capteur peuvent être représentées par un ensemble de modèles de type *segment* ou *rectangle* (ces modèles seront appelés *primitives*, en référence au terme utilisé en traitement d'images). Ces primitives, bien adaptées pour les véhicules, demeurent une bonne représentation de l'espace occupé par les objets qui ont une structure

déformable et non linéaire (par exemple les piétons). L'utilisation d'un modèle géométrique pour représenter un ensemble de mesures permet :

- d'obtenir des observations correctement localisées, même si les mouvements des objets suivis entraînent des changements de forme ;
- de réduire les données pour rendre le suivi plus efficace ;
- de fournir des informations à une éventuelle étape de classification des objets présents.

Il convient également de bien définir la représentation choisie pour les primitives et d'extraire les paramètres des données segmentées. De nombreux algorithmes de segmentation existent et quelques uns seront présentés dans la suite du rapport. Ces algorithmes doivent être précis (l'environnement polygonal obtenu doit être aussi proche que possible de la réalité), robustes (insensibles aux mesures aberrantes ou *outliers*), mais aussi travailler en temps réel avec les contraintes temporelles imposées par le capteur en mouvement.

- la classification : Les observations obtenues après la phase de segmentation peuvent appartenir à différents types d'objets. Dans l'environnement qui nous intéresse, on peut citer des voitures, des camions, des motos ou encore des piétons, néanmoins beaucoup plus rares sur les autoroutes. Il est alors souvent nécessaire de les reconnaître et les classer selon différentes caractéristiques, puisque les comportements dynamiques de chacun ne sont pas identiques.

On peut noter que certaines méthodes de suivi combinent la détection des objets et leur suivi, en utilisant les paramètres dynamiques des objets suivis dans la phase de détection [Pears, 2000]. Ce n'est pas le choix que nous avons fait, et nous considérerons pour la suite toujours la détection comme une étape préalable au suivi.

III.2 Performances des systèmes de détection

Avant toute chose, il convient de préciser que les systèmes de détection dont nous parlons sont dits à « détection automatique », c'est-à-dire sans aucune intervention humaine dans la chaîne des traitements. Les performances en détection de tels systèmes de perception se définissent avant tout au regard des objectifs et de la mission qu'ils leur sont alloués. Si on prend le cas d'un système chargé de la surveillance militaire d'une zone sensible à l'intrusion de missiles, les performances seront définies en terme de portée de détection (limite en distance au-delà de laquelle la qualité de la surveillance n'est plus correcte) ou en terme de vitesse de réaction (rapidité avec laquelle le système détecte des objets intrus dans la zone de surveillance). Pour la surveillance d'une zone sensible de type civile (surveillance de parking), les performances en vitesse sont moins importantes, mais des capacités de reconnaissance, pour des objets autorisés par exemple, sont parfois nécessaires et donc des performances de qualité de reconnaissance sont indispensables.

Dans chacun des cas, il est primordial d'analyser finement les caractéristiques spatiales, spectrales et temporelles des signaux à détecter pour adapter le système de détection à ceux-ci. Le choix du (ou des) capteur(s) à utiliser est alors possible. Mais une connaissance parfaite des conditions de fonctionnement du capteur et une modélisation des erreurs produites sur les mesures sont indispensables pour déterminer les performances de la détection. Cependant, d'autres paramètres extérieurs peuvent dégrader les signaux en amont de capteurs (milieu de propagation, masquage

parmi d'autres objets, parasites...) et de fait diminuer les performances du système de détection. D'une manière générale, les signaux provenant des objets à détecter par les capteurs actifs sont plus ou moins bruités, et la détection revient à décider de la présence ou de l'absence des objets au regard des signaux reçus par le(s) capteur(s).

Plusieurs cas sont alors envisageables :

- le système de perception détecte un objet effectivement présent dans la scène observée. C'est un cas idéal de détection.
- le système ne perçoit pas un objet présent dans la scène. C'est alors un défaut de fonctionnement du système appelé « non détection ».
- le système signale un objet qui n'est pas présent. C'est un autre défaut de fonctionnement appelé « fausse alarme ».
- le système, dit « en veille », ne détecte pas d'objet puisqu'il n'y en a pas.

Deux paramètres permettent alors de qualifier un système de détection :

- la probabilité de détection P_d : c'est la probabilité que le système détecte un objet réellement présent dans la scène.
- la probabilité de fausse alarme P_{fa} : c'est la probabilité que le système détecte un objet alors qu'il n'est pas présent dans la scène.

Un système de perception devrait avoir une probabilité de détection P_d égale à 1 (100% des objets présents détectés) et une probabilité de fausse alarme P_{fa} égale à 0 (aucune détection ne provient d'objet absent de la scène). Malheureusement, et principalement en raison du bruit sur les mesures, aucun système n'a de telles performances. On cherchera donc à obtenir P_d proche de 1 et P_{fa} la plus faible possible. Un compromis est souvent nécessaire entre ces deux grandeurs, c'est-à-dire que chercher à faire baisser P_{fa} entraîne aussi une diminution de P_d , et à l'inverse, vouloir augmenter P_d compromet la diminution de P_{fa} .

Pour notre application de suivi d'objets à l'avant d'un véhicule, il s'agit bien sûr de savoir si un objet est présent ou absent, mais les systèmes de détection doivent également être performants dans deux domaines. D'une part la précision est une performance importante, puisqu'une localisation précise des objets garantit une meilleure détermination des paramètres dynamiques des objets suivis. D'autre part la rapidité de détection est indispensable, puisque les mouvements des capteurs et des objets imposent des contraintes temporelles fortes nécessitant un fonctionnement temps réel du processus de suivi et donc une détection la plus rapide possible pour ne pas compromettre la réponse à ces contraintes. L'étude de la robustesse, pour connaître le comportement de la détection face aux *outliers*, n'est pas faite de manière formelle. Cependant, nous tenterons de donner notre avis sur la robustesse de chacune des approches présentées de manière qualitative plutôt que quantitative.

III.2.1 La détection à partir de données de type radar

C'est dans la fin des années 70 que les approches de type suivi de cibles se sont beaucoup développées. Les besoins sont apparus dans le domaine des systèmes de surveillance tant civils que militaires sur des zones étendues, où il s'agit de détecter et suivre des objets essentiellement volants à partir de radars. C'est dans ce cadre, vers la fin des années 80, que Y. Bar-Shalom et T. Fortman

[Bar Shalom, 1988] formalisent les approches de type PDA (Probabilistic Data Association), afin de résoudre le délicat problème de l'association. Ce sont ces approches que nous avons utilisées dans ce travail et que nous avons présentées plus en détail dans le chapitre précédent. Nous allons faire quelques rappels sur les principes et les techniques utilisées en détection pour des mesures provenant d'un système de type radar, avant d'évoquer les différences qu'il s'agit de prendre en compte.

En général, dans le cas du radar, le problème de détection est avant tout un problème binaire où il s'agit de déterminer la présence ou l'absence d'un objet. Pour la reconnaissance de l'objet lui-même, on peut distinguer le cas où la cible est coopérative et donc envoie des informations pour se faire reconnaître (domaine du contrôle aérien) du cas où la cible est non coopérative (domaine militaire) avec une reconnaissance de la cible qui se fait grâce à une banque de données des signatures acoustique, infrarouge, ESM (Electronic Support Measure), etc.. On localise l'objet par sa distance obtenue par une mesure du temps de vol d'une onde émise et son azimut par une mesure de déphasage, par exemple à l'aide d'une antenne directive tournante. En raison de la résolution du radar, de la taille des objets et de la configuration topologique de l'environnement observé, les objets sont souvent représentés par une seule mesure, appelée plot. On parlera alors de cible ponctuelle, au sens de la résolution du capteur.

Sans entrer dans les détails des équations du radar (on peut pour cela se référer à [Darricau, 1981]), on peut cependant dire que la prise de décision (absence ou présence) pour de tels systèmes de détection s'effectue à partir de divers critères. Le plus couramment utilisé repose sur une comparaison entre le signal électrique délivré par le capteur (souvent une tension) et une référence (souvent fixe mais éventuellement variable) qui n'est autre qu'un seuil permettant de déterminer la présence d'un signal utile dans l'ensemble du signal bruité. Toute la difficulté de la détection réside dans la détermination du seuil. En effet, si la valeur du seuil est trop élevée, le système détectera assez rarement la présence d'un signal utile et par conséquent, la probabilité de détection P_d sera faible. Et si la valeur du seuil est trop basse, alors il sera difficile de distinguer le signal utile du bruit et la probabilité de fausse alarme P_{fa} augmentera, conjointement avec la probabilité de détection (figure 54).

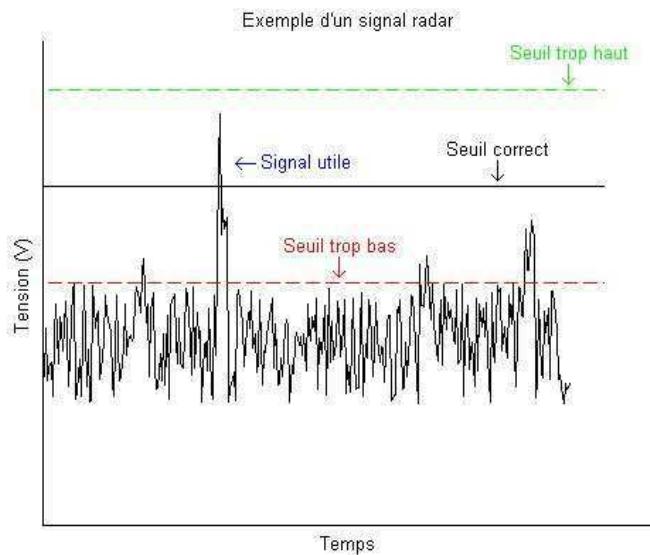


Figure 54 : Exemple d'un signal radar avec différentes valeurs de seuil.

Pour ce type de systèmes de détection, il s'agit d'adapter le seuil aux performances désirées en terme de probabilités P_d et P_{fa} . La tension de sortie V (cf. figure 54) peut être représentée par sa densité de probabilité de loi $p(V)$, telle que la probabilité de la tension V soit comprise entre v et $v+dv$ est :

$$P(v < V < v+dv) = p(V) dv.$$

Cette densité de probabilité dépend de plusieurs paramètres propres au capteur [Skolnik, 1990].

Afin d'illustrer qualitativement l'évolution des probabilités P_d et P_{fa} en fonction du seuil de détection, nous montrons sur la figure 55 différentes représentations assez schématiques de la densité de probabilité $p(V)$ pour différents signaux (bruit et signal utile faible ou fort en rapport au bruit) .

Les deux probabilités P_d et P_{fa} s'expriment de la manière suivante :

$$P_d = \text{probabilité que } (V_u + \text{bruit}) > \text{Seuil} = \int_{\text{Seuil}}^{+\infty} p(V_u + \text{bruit}) dv$$

$$P_{fa} = \text{probabilité que } \text{bruit} > \text{Seuil} = \int_{\text{Seuil}}^{+\infty} p(\text{bruit}) dv$$

Ces probabilités sont illustrées sur la figure 55 pour une densité de probabilité d'un signal utile fort par rapport au bruit. Si le signal devient plus faible, on doit alors adapter le choix de *Seuil*, pour obtenir la même probabilité de détection, faisant malheureusement augmenter la probabilité de fausse alarme. On voit donc assez aisément que le rapport signal sur bruit (RSB) est une grandeur importante pour le choix du seuil de détection.

Dans une démarche de surveillance, militaire ou civile, basée sur des capteurs actifs de type radar, on définit la probabilité de détection comme la performance essentielle à atteindre (par exemple 95%). Dans ce cadre, les capteurs utilisés doivent être parfaitement étalonnés et modélisés pour connaître les valeurs exactes de P_d et P_{fa} en fonction du RSB. Ces valeurs sont reportées sur des graphes et abaques définissant les valeurs de P_d en fonction du RSB, pour une P_{fa} donnée. On détermine alors une valeur de *Seuil*, correspondant au RSB minimum permettant d'obtenir la probabilité de détection désirée.

Une fois ce seuil déterminé, et donc P_d choisie, la probabilité de détection sera alors fixe, *i.e.* sans modification au cours de l'utilisation du processus de surveillance ou de suivi, et globale quel que soit l'objet suivi et quel que soit l'endroit où il se trouve dans la zone observée.

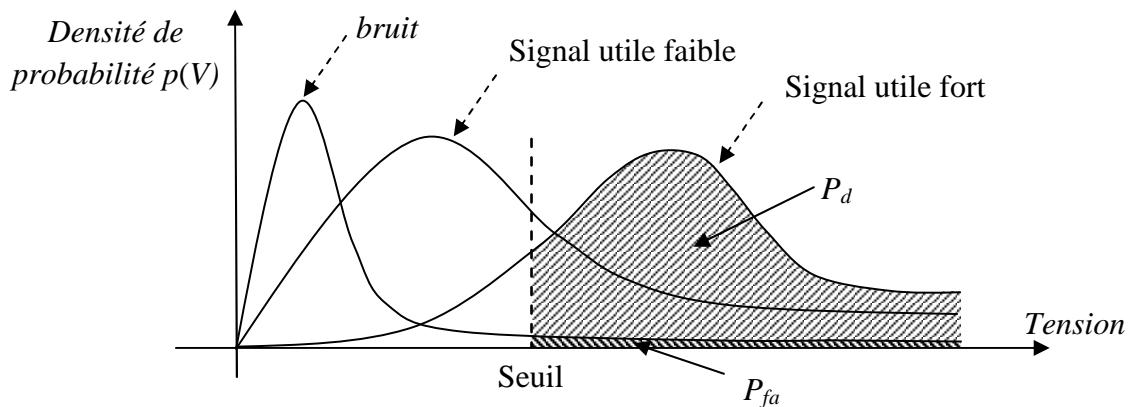


Figure 55 : Densité de probabilité du signal reçu et visualisation de P_d et P_{fa}

Certains travaux de ce domaine ont pour objectif d'optimiser l'effort de recherche en détection pour une cible donnée et parfaitement connue. Dans ce cas, la probabilité de détection est définie localement dans un espace de recherche partitionné (grille de recherche), mais elle est toujours conditionnée par un effort de recherche à effectuer pour détecter la cible [Dambreville, 2001]. La probabilité de détection P_d locale dépend alors essentiellement d'un paramètre appelé « visibilité » et de l'effort de recherche (essentiellement le temps de recherche) mis pour obtenir cette détection. La visibilité est alors un paramètre de l'environnement observé (terrain vallonné, obstacle...) et des conditions d'acquisition du signal (météo, brouillage...).

Les fouillis (ou *clutter*) sont des autres paramètres qui interviennent dans les performances de la détection par capteur radar. Ces fouillis peuvent être soit naturels de type atmosphérique (pluie, nuages...), de type topographique (sol, mer, bâtiments...) ou provenir de brouilleurs actifs ou passifs. Ces phénomènes produisent des mesures aberrantes et produisent plutôt des incertitudes sur la détection et le suivi, puisque l'on détecte et suit des objets qui n'ont pas d'intérêt pour la mission de surveillance affectée aux radars, dégradant ainsi les performances globales. Il est souvent intéressant de connaître, au moins statistiquement, ces phénomènes et des travaux traitent de la classification et de l'estimation spatio-temporelle de ces fouillis [Barbaresco, 1996].

III.2.2 La détection pour un télémètre laser à balayage

Dans notre application de surveillance, les objets suivis (que l'on appelle parfois cibles) sont rarement ponctuels à l'échelle du capteur. En effet, la taille de la zone de recherche, la taille des objets et la résolution angulaire du balayage font que plusieurs impacts voisins correspondent à un même objet (les mesures sont réparties dans la zone d'observation).

Le mode de construction d'un impact (même si la technologie n'est pas tout à fait identique) est la même. Il y a émission d'un signal, réflexion sur une surface et réception du signal réfléchi. On compare encore le signal à un seuil pour déterminer si ce signal réfléchi correspond à une surface et alors, par calcul du temps de vol, pour donner la distance de cette surface. Cette opération se répète tout le long du balayage. Il existe donc une probabilité de détection ponctuelle (pour chacun des tirs) définie par le constructeur du télémètre et qui a, à l'image des radars, permis le calcul d'un seuil. Les constructeurs ne donnent pas cette valeur de probabilité de détection ponctuelle. De plus, la réception du signal laser est très sensible à :

- la réflectivité de la surface visée (qui change beaucoup dans notre environnement) ;
- l'angle d'incidence sur la surface, qui en raison de la petite taille du faisceau, entraîne des pertes de signal.

On peut cependant mesurer cette probabilité de détection ponctuelle expérimentalement, en faisant varier les surfaces de réflexion et les orientations de ces mêmes surfaces. Elle serait définie comme la probabilité d'obtenir une mesure pour une surface présente dans une direction précise (toujours la même) du faisceau laser. Cette expérimentation est difficile à réaliser. On voit bien cependant que cette probabilité ne serait pas égale à 1.

De plus, dans le cas de mesures réparties, la détection devient beaucoup plus complexe. Elle ne correspond plus à un simple seuillage, puisque c'est un ensemble de mesures qui correspondent à un objet. La première étape est de savoir quelles sont les mesures qui appartiennent à un même objet. Afin de pouvoir suivre cet objet, la seconde étape doit faire correspondre ces mesures à un modèle

de l'objet, préalablement choisi, pour mesurer les paramètres désirés, par exemple les mesures en position et en orientation de l'objet. Ce sont ces deux étapes qui forment la détection pour des données télémétriques issues d'un balayage. Ces étapes sont réalisées par des algorithmes, plus ou moins complexes en fonction des performances de la détection désirées, à partir de la succession des données brutes ponctuelles.

Les algorithmes successifs nécessitent l'utilisation de seuils (certains algorithmes seront détaillés dans la suite). Ces seuils déterminent les performances propres de chacun des algorithmes présents dans la chaîne de détection. Mais, contrairement à la détection sur données radar, il est inenvisageable, vu la complexité, de déterminer ces différents seuils en fonction d'une performance globale de la détection donnée par une probabilité de détection P_d globale. L'évaluation des performances globales de la détection, i.e. la détermination de P_d et P_{fa} se fera par une évaluation en aval de l'ensemble des algorithmes de détection à partir d'un protocole défini précisément. Ces probabilités seront alors fixes (non modifiées dans le temps d'utilisation des algorithmes) et globales (toujours vraies quel que soit l'objet suivi et quelle que soit sa position dans l'espace observé).

Intuitivement, on sent bien que le nombre d'impacts permettant de détecter un objet sera un facteur déterminant dans la qualité de la détection. La probabilité de détection d'un objet pourra donc évoluer en fonction de sa taille, de sa position dans l'espace observé mais aussi de la présence d'autres objets dans la scène susceptibles d'occulter partiellement ou en totalité l'objet suivi. Il est donc envisageable d'imaginer une évolution de la probabilité de détection propre à chacun des objets suivis. C'est sur ce constat qu'une partie de notre apport réside dans ce travail.

Mais avant cela, nous allons présenter les algorithmes de détection que nous avons utilisés, et pour certains développés en ayant auparavant fait un bref retour sur la représentation des mesures télémétriques et de leurs imprécisions associées.

III.3 Les données télémétriques

III.3.1 Expression des mesures

Considérons une acquisition d'un capteur télémétrique obtenue après un balayage de la zone observée. Ce balayage comporte des mesures successives ordonnées où la mesure du $i^{\text{ème}}$ impact t_i est définie par :

- $t_i = (\rho_i, \theta_i)$ en coordonnées polaires si on l'exprime dans le repère du capteur ;
- $t_i = (x_i, y_i)$ en coordonnées cartésiennes si on l'exprime dans un repère (θ, x_w, y_w) commun appelé « Repère du monde ».

Le passage d'un repère à l'autre s'effectue simplement (figure 56) par :

$$\begin{cases} x_i = \rho_i \cos \theta_i \\ y_i = \rho_i \sin \theta_i \end{cases} \quad (1)$$

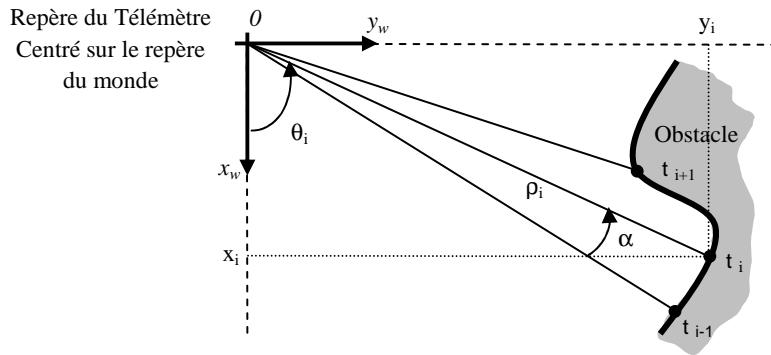


Figure 56 : Repérage des impacts.

Le nombre de mesures, que nous appellerons *MaxImpacts*, obtenues par balayage dépend, pour les télémètres, de l'ouverture et de la résolution angulaire α . Pour le type de télémètre que nous utilisons, nous donnons quelques valeurs caractéristiques de *MaxImpacts* :

Ouverture	Résolution Angulaire α	Nombre de mesures (<i>MaxImpacts</i>)
$(+ 50^\circ ; -50^\circ)$	1°	101
	$0,5^\circ$	201
	$0,25^\circ$	401
$(+ 90^\circ ; -90^\circ)$	1°	181
	$0,5^\circ$	361
	$0,25^\circ$	721

Tableau 10 : Grandeur caractéristique de *MaxImpacts*.

Etant donné les angles d'ouverture potentiels du télémètre, nous veillerons également à ce que tous les angles θ soient exprimés dans les deux premiers cadrans, i.e. $0 \leq \theta \leq \pi$.

III.3.2 Imprécisions et incertitudes sur les mesures

Pour le type de capteur utilisé (LMS© 200 et IBEO LD Automobile monoplan), les erreurs de mesures (en distance ρ et en angle θ) sont généralement modélisées par des grandeurs gaussiennes de moyenne nulle et de variances σ_ρ^2 et σ_θ^2 . Les angles et les distances étant des grandeurs indépendantes, les covariances sont nulles. Selon les données constructeurs, l'erreur expérimentale sur la distance ρ est de l'ordre du centimètre quelle que soit la distance (+/-5cm pour IBEO, soit $\sigma_\rho=5.10^{-2}$ m, et +/-3cm pour le LMS, soit $\sigma_\rho=3.10^{-2}$ m). Les ordres de grandeur de ces erreurs ont été vérifiés expérimentalement. L'erreur expérimentale angulaire est, quand à elle, donnée nulle par le constructeur, en raison de la bonne répétabilité du système de balayage angulaire. Toutefois, pour prendre en compte les erreurs de quantification dans la numérisation des angles, nous avons modélisé l'erreur angulaire avec un écart-type très faible de l'ordre de $\sigma_\theta=10^{-3}$ rad.

Si les mesures sont exprimées dans le repère cartésien du monde, on peut faire l'hypothèse que les erreurs restent des variables gaussiennes centrées en calculant une approximation des covariances (en négligeant les termes d'ordre supérieur à 2). Ces variances sont alors données par :

$$\begin{cases} \sigma_{x_i}^2 \approx \sigma_\rho^2 \cos^2 \theta_i + \sigma_\theta^2 \rho_i^2 \sin^2 \theta_i \\ \sigma_{y_i}^2 \approx \sigma_\rho^2 \sin^2 \theta_i + \sigma_\theta^2 \rho_i^2 \cos^2 \theta_i \\ \sigma_{x_i y_i} \approx [\sigma_\rho^2 - \sigma_\theta^2 \rho_i^2] \frac{\sin 2\theta_i}{2} \\ \sigma_{y_i x_i} \approx \sigma_{x_i y_i} \end{cases} \quad (2)$$

Et si on néglige σ_θ (en accord avec les données constructeurs), on peut avoir une approximation des écarts-types pour les mesures $t_i = (x_i, y_i)$:

$$\begin{cases} \sigma_{x_i} \approx \sigma_\rho |\cos \theta_i| \\ \sigma_{y_i} \approx \sigma_\rho |\sin \theta_i| \end{cases}$$

On notera toutefois que les variables x_i et y_i ne sont pas mutuellement indépendantes.

Des mesures aberrantes peuvent apparaître lors de l'acquisition. Ces mesures, à rapprocher du fouillis dans les données radar, peuvent avoir plusieurs sources. On peut citer :

- une mauvaise réflexion sur la surface visée due au matériau ;
- un angle d'incidence qui produit une erreur dans la durée du temps de vol de l'onde ;
- un tangage du véhicule porteur du capteur qui provoque des réflexions sur la route par exemple ;
- une inclinaison de la route ;

Ces mesures incertaines, appelées *outliers*, vont altérer les performances des algorithmes de détection et il est important de donner la capacité à ces algorithmes d'être robustes face à ces mesures.

III.4 Le clustering

Comme nous l'avons vu dans le chapitre précédent, on entend par *clustering*, la division d'un ensemble de données en sous-ensembles (appelés *clusters*) formés de données ayant un caractère commun. Le *clustering* est fortement développé dans les domaines de la reconnaissance des formes ou de la classification des données. Les algorithmes, dont l'un des plus connus est le *K-means* sont basés sur le calcul de centroïdes selon un processus itératif. Nous avons présenté deux de ces algorithmes dans le chapitre précédent, mais au final ce type de calcul ne semble pas très utile pour des données provenant d'un balayage, surtout parce que les impacts sont ordonnés et que des impacts provenant d'un même objet sont forcément consécutifs (pour les télémètres considérés dans ce travail). Les algorithmes de *clustering* ne vont être présentés ici que sous des formes adaptées au groupement des données télémétriques provenant d'un capteur à balayage. Ce groupement en *clusters* des données télémétriques prend des dénominations différentes dans la littérature. Dans [Borges, 2004], il s'agit de détection de points de rupture (*breakpoint detection*). Dans d'autres références ([Dietmayer, 2001], [Santos, 2003], [Premebida, 2005]), on parle de *segmentation*, entraînant une confusion puisqu'ils ne décrivent bien que des algorithmes de groupements en *clusters* d'impacts. Finalement dans [Nguyen, 2005] et [Keat, 2005], c'est bien le terme *clustering* qui décrit cette étape de groupement en *clusters* (c'est aussi celui là que nous retiendrons dans la suite du rapport).

La plupart des algorithmes de *clustering* (dont l'un des plus connus est le *K-means*) sont basés sur le calcul de centroïdes selon un processus itératif. Ce type de calcul n'est pas très utile pour des données provenant d'un balayage, surtout parce que les impacts sont ordonnés et que des impacts provenant d'un même objet sont forcément consécutifs. Dans la première approche du chapitre II, nous avons cependant détecté des clusters par ce type d'approche, mais on ne s'intéressait alors qu'aux centres de gravités de ces groupes comme éléments de représentation des objets.

L'étape de *clustering*, appliquée à un balayage laser, consiste à trouver les limites des objets mesurés par le télémètre. Il s'agit donc de trouver des sous-groupements d'impacts provenant d'un même objet, en détectant les discontinuités en distance sur la totalité des impacts du balayage.

L'algorithme général du clustering se présente comme suit :

Algorithme 1 : Algorithme Général de *clustering*

```

Pour  $i = 1$  jusqu'à  $MaxImpacts$  faire
  Si  $D(t_i, t_{i+1}) > D_{seuil}$  Alors
     $t_{i+1}$  initialise un nouveau cluster
  Sinon
     $t_{i+1}$  est regroupé au cluster courant
  FindeSi
FindePour

```

La distance euclidienne entre deux impacts successifs $D(t_i, t_{i+1})$ est donnée par :

$$D(t_i, t_{i+1}) = \sqrt{\rho_i^2 + \rho_{i+1}^2 - 2 \rho_i \rho_{i+1} \cos \alpha} \quad \text{en coordonnées polaires}$$

$$D(t_i, t_{i+1}) = \sqrt{(x_i - x_{i+1})^2 + (y_i - y_{i+1})^2} \quad \text{en coordonnées cartésiennes}$$

La principale difficulté du *clustering* réside dans la détermination de D_{seuil} . Ce paramètre de l'algorithme peut être choisi constant quelle que soit la position des impacts dans l'espace de recherche. On parlera alors d'algorithme non adaptatif. Cependant, la distance entre deux impacts successifs est d'une part fonction de la distance entre la surface visée et le capteur, mais aussi de l'orientation de la surface relativement à l'angle des faisceaux. Une distance D_{seuil} constante est donc très peu envisageable.

Pour illustrer ce problème, on peut voir sur la figure 57, que le seuil constant permet de séparer les 2 *clusters* puisque $D_2 > D_{seuil}$. Par contre, il sera difficile de retrouver le second ensemble de points car la distance entre les impacts augmente avec la distance surface-capteur et on a par exemple $D_1 > D_{seuil}$.

Vue sa simplicité, un *clustering* non adaptatif est toutefois envisageable dans le cas d'un partitionnement grossier de l'ensemble des impacts, pour réduire par exemple les coûts calculatoires des algorithmes de segmentation. La distance D_{seuil} sera alors choisie en fonction de connaissances *a priori* sur la scène observée. Par exemple, dans le cas de trafic de véhicules sur autoroute, il est peu probable d'avoir des distances entre véhicules inférieures à 0,5 m. C'est cette distance qui pourra alors être choisie comme seuil.

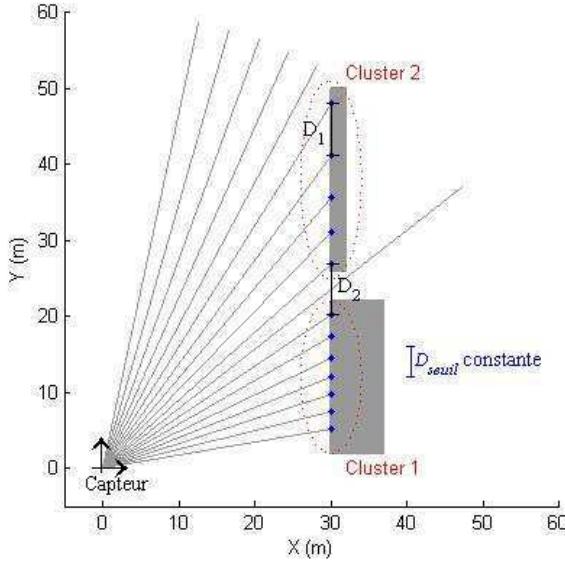


Figure 57 : Illustration du problème du clustering non adaptatif.

Si le paramètre D_{seuil} est variable alors l'algorithme est dit « adaptatif ».

III.4.1 Clustering adaptatif

Pour pallier les problèmes du *clustering* non adaptatif, les méthodes adaptatives déterminent des valeurs de D_{seuil} à chaque itération de l'algorithme 1. Comme il s'agit de *clustering*, ces seuils sont également appelés « critères » puisqu'ils représentent les critères à remplir par le point testé pour faire partie du même *cluster* que le point précédent. Nous allons présenter trois des critères que l'on trouve dans la littérature. Le calcul de chacun des seuils ne sera pas détaillé (on peut les trouver dans les références correspondantes), mais quelques termes typiques des formules seront explicités.

Critère de Dietmayer

Le critère de Dietmayer [Dietmayer, 2001] s'exprime par :

$$D_{seuil} = C_a \cdot \min \{\rho_i, \rho_{i+1}\} + C_{bruit},$$

avec $C_a = \sqrt{2(1 - \cos \alpha)},$

et C_{bruit} un paramètre constant qui permet de prendre en compte l'influence du bruit en distance des impacts. Typiquement, on choisit $C_{bruit} = 3\sigma_\rho$.

Ce seuil dépend bien de la distance entre la surface d'impact et le repère du télémètre. Cependant cette dépendance est forte, et si les impacts sont très éloignés du capteur, il devient alors difficile de séparer les *clusters*. De plus, l'orientation des surfaces visées n'est pas prise en compte. En effet, le terme C_a ne dépend que de la résolution angulaire et a été obtenu avec l'hypothèse que la surface est perpendiculaire à la bissectrice de (θ_i, θ_{i+1}) . L'inclinaison de la surface, qui est également un facteur déterminant de la distance entre les impacts, n'est pas prise en compte.

Critère de Santos

A partir du critère de Dietmayer, Santos *et al.* [Santos, 2003] propose de prendre en compte l'inclinaison de la surface visée dans un nouveau critère par l'introduction d'un angle β (on peut voir sur la figure 58 où est situé cet angle). Ce terme, qu'il faut fixer au préalable, représente une inclinaison maximale de la surface pour laquelle l'impact t_{i+1} pourra répondre au critère de distance et donc être intégré au *cluster* en cours. Le seuil devient alors :

$$D_{\text{seuil}} = C_a \cdot \min \{\rho_i, \rho_{i+1}\} \cdot \frac{1}{\cotg(\beta) \cdot \cos(\frac{\alpha}{2}) - \sin(\frac{\alpha}{2})} + C_{\text{bruit}}$$

Typiquement, β est fixé expérimentalement autour de 60° . Ce choix de β est primordial, puisque s'il est choisi trop grand, il sera difficile de séparer deux *clusters* provenant de deux objets, et s'il est choisi trop petit, on risque de séparer deux impacts successifs provenant d'une même surface.

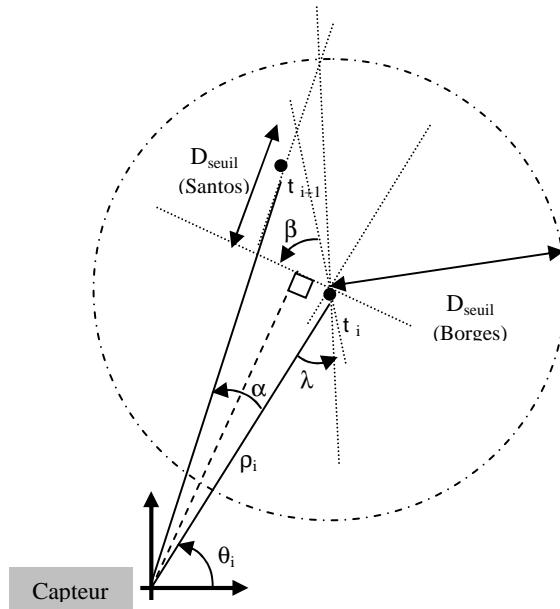


Figure 58 : Visualisation des D_{seuil} de Santos et Borges.

Critère de Borges

Un autre critère prenant en compte l'orientation maximale de la surface pour agréger l'impact au *cluster* est donné dans Borges *et al.* [Borges, 2004]. Ce critère, plutôt utilisé dans une démarche de détection de rupture (issue de changement d'objet), prend en compte uniquement le point courant t_i comme référence. Un angle λ détermine alors l'orientation admissible de la surface. Le critère devient alors :

$$D_{\text{seuil}} = \rho_i \cdot \frac{\sin(\alpha)}{\sin(\lambda - \alpha)} + C_{\text{bruit}}$$

Ce paramètre λ (figure 58) peut être vu comme un angle limite de la surface pour lequel le télémètre ne délivrera pas de mesures (en raison du problème de réflexion puisque la surface est quasiment parallèle au faisceau). Cette grandeur, donnée par les constructeurs est de l'ordre de 10° . En pratique, il convient de prendre λ de l'ordre de 25° pour ne pas entraîner un seuil trop grand et donc être incapable de séparer deux *clusters*.

Certains auteurs ne se basent plus sur un critère de distance entre les points pour séparer les *clusters*, mais utilisent une approche de type *détection de rupture* basée sur le filtre de Kalman [Roumeliotis, 2000]. En l'occurrence puisque les équations d'états présentent des non linéarités, il s'agit d'un filtre de Kalman étendu (EKF). L'appartenance d'un point à un *cluster* se détermine par la comparaison d'une distance statistique de Mahalanobis à un seuil. Si cette distance est inférieure au seuil, alors le point est assimilé au *cluster* en cours. Sinon, un nouveau *cluster* commence. Nous avons testé cette approche qui n'est pas difficile à mettre en oeuvre. Cependant, l'initialisation des filtres à chaque début de *clusters* n'est pas sans poser de problème et peut entraîner un mauvais *clustering*. De plus, les calculs sont sensiblement plus lourds qu'un *clustering* basé sur une distance déterministe et n'apporte pas d'information sur les paramètres des primitives. C'est pour cette raison que nous avons utilisé de préférence un *clustering* classique.

Cette étape de *clustering* est un préalable à la segmentation, puisqu'elle ne permet d'obtenir que des ensembles d'impacts supposés appartenir à un même objet sans déterminer les paramètres des primitives choisies pour le représenter. Elle permet cependant d'améliorer la robustesse de la détection aux *outliers* (en les éliminant), et très souvent d'augmenter la précision et la rapidité de la détection. Cette étape n'est cependant pas obligatoire et il convient d'analyser des performances avec et sans *clustering* pour garantir l'apport de celui-ci dans les performances de la détection.

III.5 La segmentation

La segmentation peut être vue comme l'extraction, à partir des mesures du télémètre, des paramètres d'un modèle de l'objet choisi. En référence au traitement de l'image, ce modèle est couramment appelé *primitive*. L'objet détecté est alors représenté par une primitive ou un ensemble de primitives. Le choix du type de primitives pour représenter au mieux l'environnement est important. Nous avons choisi le segment, qui reste la primitive la plus naturelle et la plus utilisée pour le type d'environnement très structuré et le type de mesures à traiter. Il existe cependant plusieurs manières de représenter un segment mais, en général, l'orientation de la droite support est un des paramètres car celui-ci est peu sensible à la quantité de points utilisés. Ensuite, pour obtenir une détermination complète, on ajoute soit le milieu du segment et sa longueur ou alternativement ses deux extrémités.

Cependant, le segment n'est pas une primitive sans risque dans le sens où, comme nous allons le présenter, elle peut engendrer des mouvements inexistant des objets suivis. Nous expliquerons alors pourquoi, une primitive de type rectangle (composée d'un ensemble de primitives segments) résout en partie ce problème.

Nous allons présenter quelques algorithmes de segmentation, certains juste selon leurs principes et d'autres, que nous avons implantés, avec plus de détails. Ces derniers serviront essentiellement de comparaison pour un algorithme que nous avons développé et qui repose surtout sur la présence d'un invariant en distance dans les données appartenant à un segment (plus exactement à une droite). La plupart des méthodes rencontrées déterminent, quand cela est nécessaire, les paramètres d'une droite à partir des impacts par minimisation d'un critère quadratique (généralement à base de moindres carrés). Nous évoquerons ce point, en précisant qu'il est nécessaire de traiter ce problème, qui devient alors non linéaire, en coordonnées polaires. De plus, lors de l'extraction des paramètres, nous donnerons, dans la mesure du possible, les imprécisions associées à chacun des paramètres.

III.5.1 Détermination par minimisation quadratique

Une des techniques les plus communes pour ajuster un modèle mathématique à un ensemble de données, nous concernant en deux dimensions, est la méthode de minimisation d'un critère quadratique, appelée aussi méthode des moindres carrés.

De manière très générale, le modèle est linéaire et rend compte d'une situation dans laquelle la moyenne d'un vecteur aléatoire \mathcal{Y} , constitué des observations, dépend linéairement et explicitement d'un vecteur de paramètres \mathcal{X} :

$$\mathcal{Y} = \mathcal{H} \cdot \mathcal{X} + \varepsilon, \quad E(\mathcal{Y}) = \mathcal{H} \cdot \mathcal{X}, \quad \text{Var}(\mathcal{Y}) = \text{Var}(\varepsilon) = \sigma^2 I$$

Où $E(\cdot)$ et $\text{Var}(\cdot)$ sont l'espérance mathématique et la variance de la variable aléatoire.

Sous l'hypothèse gaussienne, les observations sont des variables aléatoires de même variance et indépendantes (la partie aléatoire est amenée par le vecteur d'erreur ε , de composantes centrées, non corrélées et de variance σ^2). Pour la résolution par les moindres carrées, les colonnes de \mathcal{X} représentent des variables, éventuellement observées, mais parfaitement connues, c'est-à-dire non aléatoires.

Lorsque les observations ne présentent pas toutes la même variance (les variances des erreurs ne sont pas constantes), alors la solution est donnée par la méthode des moindres carrés pondérés. Lorsque la relation n'est plus linéaire, il est possible d'utiliser une approximation linéaire par un développement de Taylor, sous l'hypothèse de conserver les caractéristiques statistiques des grandeurs, au moins pour les deux premiers moments (moyenne et variance).

L'extraction des paramètres de droites par des méthodes des moindres carrés est très sensible aux points aberrants (*outliers*). On comprend aisément que si un ou plusieurs points, par lesquels on cherche à faire passer la droite, n'appartiennent pas en réalité à la droite, alors les paramètres du modèle seront tout de même affectés par ces points. C'est pour cela que la robustesse de la méthode nécessite de ne traiter que des points réputés appartenir à la droite (*inliers*) et impose au préalable un *clustering*, limitant ainsi les effets néfastes des *outliers*.

III.5.1.1 Extraction de droites en coordonnées cartésiennes

Pour traiter le problème d'extraction des paramètres d'une droite en coordonnées cartésiennes, il faut tout d'abord transformer, à l'aide des formules (1), les données capteur en données exprimées dans le repère orthogonal commun ($0, x, y$). Les imprécisions associées sont fournies par les équations (2).

Nous avons donc n impacts sous forme de coordonnées (x_i, y_i) , et on cherche une droite d'équation $y = a x + b$ qui soit la plus proche possible de l'ensemble des points (figure 59). Nous ne détaillerons pas ici la méthode des Moindres Carrés classique couramment appliquée à ce problème.

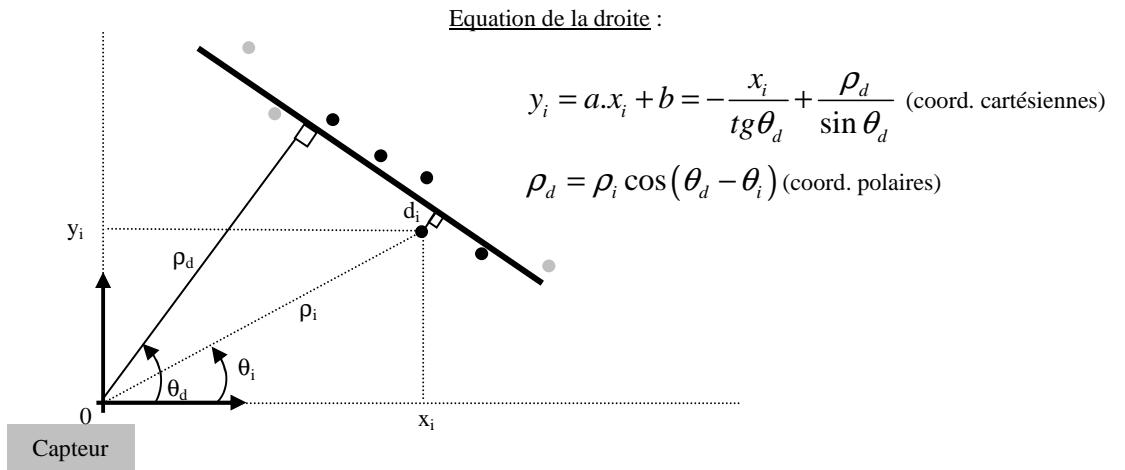


Figure 59 : Illustration de l'extraction de droite à partir d'impacts.

L'utilisation d'une méthode des Moindres Carrés, dans le cas des impacts lasers exprimés en coordonnées cartésiennes, pose cependant certains problèmes que nous allons évoquer :

- l'hypothèse de départ qui suppose d'avoir une connaissance déterministe des termes de \mathcal{X} n'est pas respectée. En effet, les imprécisions sur l'abscisse x_i des impacts présentent un caractère aléatoire et varient fortement en fonction de l'angle θ_i , *i.e.* de la position de l'impact (*cf.* équation 2).
- pour tenter de résoudre ce problème, il est possible soit d'essayer de trouver une approximation pour reporter les erreurs présentes dans \mathcal{X} sur ε (et donc sur \mathcal{Y}) ou encore tenter de borner les erreurs sur \mathcal{X} et \mathcal{Y} . Mais, en tout état de cause, la solution deviendra sous-optimale au sens des Moindres Carrés et il faudra impérativement utiliser une approche de type *Moindres Carrés Pondérés* puisque les erreurs ne sont plus constantes quelles que soient (x_i, y_i) .
- les imprécisions sur les paramètres (a et b) peuvent bien sûr être calculées. Cependant, le caractère gaussien de ces termes n'est plus tout à fait vérifié, essentiellement en raison de la transformation (*polaire* \rightarrow *cartésien*). Si, de plus, on veut retrouver les paramètres polaires de la droite (ρ_d et θ_d), il faudra refaire la transformation en sens inverse (*cartésien* \rightarrow *polaire*) pour les paramètres et les imprécisions associées. Il sera alors impossible de conserver le caractère gaussien de ces paramètres.

III.5.1.2 Extraction de droites en coordonnées polaires

Il s'agit d'extraire les paramètres (ρ_d, θ_d) d'une droite polaire $\rho_i \cos(\theta_d - \theta_i) - \rho_d = 0$ à partir de n impacts $t_i = (\rho_i, \theta_i)$ avec $i = 1, \dots, n$ (*cf.* figure 59). Les impacts sont modélisés comme des variables aléatoires indépendamment affectées à un bruit gaussien pour les deux coordonnées. Nous avons donc :

$$\begin{aligned} \forall \quad i, j = 1, \dots, n, \\ \rho_i &\cong N(\bar{\rho_i}, \sigma_{\rho_i}^2) & E\{\rho_i \cdot \rho_j\} &= E\{\rho_i\}E\{\rho_j\} & E\{\theta_i \cdot \theta_j\} &= E\{\theta_i\}E\{\theta_j\} \\ \theta_i &\cong N(\bar{\theta_i}, \sigma_{\theta_i}^2) & E\{\rho_i \cdot \theta_j\} &= E\{\rho_i\}E\{\theta_j\} \end{aligned}$$

Le modèle de la droite choisi (*i.e.* $\rho_i \cos(\theta_d - \theta_i) - \rho_d = 0$) minimise la distance orthogonale d_i de chaque impact à la ligne (contrairement aux méthodes des Moindres Carrés usuelles). La distance d_i est donnée par :

$$d_i = \rho_i \cos(\theta_d - \theta_i) - \rho_d$$

La somme S de ces erreurs au carré est :

$$S = \sum_{i=1}^n d_i^2 = \sum_{i=1}^n (\rho_i \cos(\theta_d - \theta_i) - \rho_d)^2$$

Les paramètres ρ_d et θ_d du modèle sont obtenus en résolvant le système d'équations non linéaires :

$$\frac{\partial S}{\partial \rho_d} = 0 \text{ et } \frac{\partial S}{\partial \theta_d} = 0$$

Une solution du type Moindres Carrés Pondérés est proposée dans [Arras, 1998] puisque les impacts $t_i = (\rho_i, \theta_i)$ ont des variances $\sigma_{\rho_i}^2$ qui évoluent en fonction de ρ_i et des variances $\sigma_{\theta_i}^2$ quasiment nulles. Les poids sont alors classiquement pris égaux à $1/\sigma_{\rho_i}^2$. Un calcul des imprécisions sur les paramètres du modèle est également proposé. Il repose sur une approche de type *propagation des erreurs*.

En ce qui nous concerne, les variances $\sigma_{\rho_i}^2$ sont toutes égales, indépendantes de la distance ρ_i , et les variances $\sigma_{\theta_i}^2$ peuvent être considérées comme nulles. Les poids disparaissent donc de la solution (en fait, il s'agit d'une solution du type Moindres Carrés simple). Nous avons alors :

$$\theta_d = \frac{1}{2} \operatorname{arctg} \left(\frac{N}{D} \right) = \frac{1}{2} \operatorname{arctg} \left(\frac{\frac{2}{n} \sum_{i=1}^n \sum_{j=1}^n \rho_i \rho_j \sin(\theta_i) \cos(\theta_j) - \sum_{i=1}^n \rho_i^2 \sin 2\theta_i}{\frac{1}{n} \sum_{i=1}^n \sum_{j=1}^n \rho_i \rho_j \cos(\theta_i + \theta_j) - \sum_{i=1}^n \rho_i^2 \cos 2\theta_i} \right) \quad (3)$$

$$\rho_d = \frac{1}{n} \sum_{i=1}^n \rho_i \cos(\theta_i - \theta_d) \quad (4)$$

On calcule tout d'abord l'angle de la droite, en veillant à obtenir un angle θ_d qui corresponde au modèle en tenant compte de la détermination de la tangente à π près. En ce qui nous concerne, nous avons un modèle de droite support tel que $0 \leq \theta_d \leq \pi$. Une fois l'angle de la droite support obtenu, le calcul de ρ_d revient simplement à une moyenne de cette distance pour chacun des impacts.

Puisque $x_i = \rho_i \cos \theta_i$ et $y_i = \rho_i \sin \theta_i$, les calculs des paramètres de la droite polaire peuvent être exprimés, sans approximation, en cartésien :

$$\theta_d = \frac{1}{2} \operatorname{arctg} \left(\frac{-2 \sum_{i=1}^n (y_{moy} - y_i)(x_{moy} - x_i)}{\sum_{i=1}^n (y_{moy} - y_i)^2 - (x_{moy} - x_i)^2} \right)$$

$$\rho_d = x_{moy} \cos \theta_d + y_{moy} \sin \theta_d$$

$$\text{avec } x_{moy} = \frac{1}{n} \sum_{i=1}^n x_i \text{ et } y_{moy} = \frac{1}{n} \sum_{i=1}^n y_i .$$

Pour le vecteur de paramètres $para = (p_d \quad \theta_d)^t$, les imprécisions s'expriment alors, en négligeant les erreurs sur θ_d , par la matrice de covariance :

$$\text{Cov}_{para} = \begin{pmatrix} \sigma_{p_d}^2 & \sigma_{p_d \theta_d} \\ \sigma_{\theta_d p_d} & \sigma_{\theta_d}^2 \end{pmatrix}$$

L'expression des différentes valeurs reprend les termes N et D de l'équation (3) :

$$\begin{aligned} \sigma_{p_d}^2 &= \sum_{i=1}^n \left[\frac{1}{n} \cos(\theta_i - \theta_d) + A(y_{moy} \cos \theta_d - x_{moy} \sin \theta_d) \right]^2 \sigma_{\rho_i}^2 \\ \sigma_{\theta_d}^2 &= \frac{1}{(D^2 + N^2)^2} \sum_{i=1}^n [N(x_{moy} \cos \theta_i - y_{moy} \sin \theta_i - \rho_i \cos 2\theta_i) - D(x_{moy} \sin \theta_i + y_{moy} \cos \theta_i - \rho_i \sin 2\theta_i)]^2 \sigma_{\rho_i}^2 \\ \sigma_{p_d} \sigma_{\theta_d} &= \sigma_{\theta_d} \sigma_{p_d} = \sum_{i=1}^n A \cdot B \cdot \sigma_{\rho_i}^2, \end{aligned}$$

avec les termes A et B qui représentent les dérivées partielles :

$$\begin{aligned} A &= \frac{\partial D}{\partial \rho_i} = \frac{\frac{\partial D}{\partial \theta_d} N - \frac{\partial N}{\partial \rho_i} D}{2(D^2 + N^2)} = \frac{N(x_{moy} \sin \theta_i + y_{moy} \cos \theta_i - \rho_i \sin 2\theta_i) - D(x_{moy} \cos \theta_i - y_{moy} \sin \theta_i - \rho_i \cos 2\theta_i)}{D^2 + N^2} \\ B &= \frac{\partial \rho_d}{\partial \rho_i} = \frac{\partial}{\partial \rho_i} \left\{ \frac{1}{n} \sum_{j=1}^n \rho_j \cos(\theta_j - \theta_d) \right\} = \frac{1}{n} \cos(\theta_i - \theta_d) + A(y_{moy} \cos \theta_d - x_{moy} \sin \theta_d) \end{aligned}$$

Tous les éléments de la matrice Cov_{para} sont de complexité $O(n)$ mais sont déterminés en grande partie avec des termes calculés au préalable. Ces calculs, qui peuvent sembler lourds, ne vont donc pas ralentir outre mesure les processus de détection qui les utilisent.

III.5.2 Quelques algorithmes de segmentation

Il existe de nombreux algorithmes de segmentation pouvant être adaptés à la détection de droites dans des données télémétriques telles que celles que nous traitons. Il ne s'agit pas ici d'en faire une étude exhaustive mais nous allons toutefois présenter les plus courants. Nous avons étudié ceux qui nous semblent les plus performants en termes de robustesse (sensibilité aux *outliers*), de précision voire même de rapidité. Les grandes lignes de ces algorithmes seront présentées en pseudo-code. Pour les autres algorithmes, nous en donnerons les principes ainsi que leurs défauts et leurs qualités. Une bonne évaluation des nombreuses méthodes existantes se trouve dans [Nguyen, 2007], mais pour des données télémétriques d'un environnement intérieur. Pour les algorithmes implémentés, une comparaison des performances sera donnée en fin de ce chapitre.

III.5.2.1 Algorithme Incrémental (ou *Line Tracking*)

Cet algorithme (Algorithme 2) se base sur les calculs successifs des paramètres de la droite (par la méthode présentée dans le paragraphe précédent). Un nouvel impact t_n appartiendra à la droite si la distance orthogonale qui le sépare de la droite, calculée jusqu'à t_{n-1} , est inférieure à un seuil fixé. Si c'est le cas, les paramètres de la droite sont recalculés en incluant l'impact t_n . Sinon, une nouvelle droite commence.

La complexité de l'algorithme Incrémental est $Comp_{inc} = S \times Nb_{impacts}^2$ où S est le nombre de segments extraits par l'algorithme pour les $Nb_{impacts}$ impacts à traiter.

Les avantages de cet algorithme sont :

- une relative simplicité de mise en œuvre ;
- une programmation séquentielle qui permet une implantation en ligne durant l'acquisition. Dans ce cas, la méthode ne doit pas être précédée d'un *clustering*.

Algorithme 2 : Algorithme Incrémental (*Line Tracking*)

Entrée : un ensemble $\{t_1, \dots, t_n\}$ d'impacts

$i \leftarrow 1$

$j \leftarrow 1$

TantQue $j < n-2$ **faire**

$S \leftarrow$ droite ajustée aux impacts $\{t_i, \dots, t_{j+1}\}$ par minimisation quadratique

$d \leftarrow$ la distance orthogonale entre t_{j+2} et S

Si $d > d_{max}$ **Alors**

Stocker S

$i \leftarrow j+2$

$j \leftarrow i$

Sinon

$j \leftarrow i+1$

FinSi

FinTantQue

Les inconvénients sont :

- lors de l'initialisation d'une nouvelle droite (les paramètres sont calculés à partir de 2 impacts successifs), il est possible de prendre en compte un *outlier* et alors le point suivant ne sera pas assimilé à la droite. Le manque de *clustering* peut donc entraîner un morcellement de la droite. On peut tenter de résoudre en partie ce problème en initialisant avec plus de points consécutifs (entre 3 et 5 points) et/ou en proposant un *clustering* grossier (avec seuil constant) en amont de l'algorithme.
- la détermination du seuil est délicate, puisqu'il s'agit d'un seuil fixe. Une valeur de seuil trop faible conduit à un morcellement des droites éloignées du capteur et une valeur trop grande peut conduire à des associations aberrantes d'impacts pour des droites proches du capteur.

Une évaluation quantitative de cette méthode sera donnée par la suite.

III.5.2.2 Algorithmes de type *Split and Merge*

Ces algorithmes de segmentation sont probablement les plus utilisés. Ils se décomposent en deux phases. La première phase est récursive et consiste à diviser (*split*) les ensembles de points disponibles appartenant à une droite, que nous appelons segments, en des segments plus petits. La seconde phase permet de fusionner (*merge*) les segments obtenus s'ils sont presque colinéaires.

Nous allons présenter deux algorithmes de division. Le premier (Algorithme 3) s'appelle *Iterative End Point Fit* (IEPF) et ne nécessite la détermination des paramètres de la droite en n'utilisant que les deux points extrêmes de l'ensemble des points traités. Le second (Algorithme 4) est une adaptation de l'IEPF et est connu sous la dénomination de *Split*. Les paramètres de la droite sont cette fois-ci déterminés par minimisation quadratique.

Algorithme 3 : Algorithme Iterative End Point Fit (IEPF)

Fonction IEPF (\mathcal{T})

Entrée : $\mathcal{T} \leftarrow \{t_1, \dots, t_n\}$

Mettre \mathcal{T} dans la liste \mathcal{L}

$S \leftarrow$ droite passant par les 2 points extrêmes de \mathcal{T}

$t_{max} \leftarrow$ le point de \mathcal{T} avec la plus grande distance orthogonale d à S

Si $d > d_{max}$ **Alors**

$\mathcal{T}' \leftarrow \{t_1, \dots, t_{max}\}$

$\mathcal{T}'' \leftarrow \{t_{max}, \dots, t_n\}$

$\mathcal{L} \leftarrow$ IEPF (\mathcal{T}')

$\mathcal{L} \leftarrow$ IEPF (\mathcal{T}'')

$\mathcal{L} \rightarrow \mathcal{T}$

% éliminer \mathcal{T} de la liste \mathcal{L}

FinSi

Retourner \mathcal{L}

FinFonction

Ces deux algorithmes ont la même complexité qui dépend essentiellement du nombre d'impacts à traiter. Elles sont données par $Comp_{Split \& Merge} = Nb_{impacts} \times \log Nb_{impacts}$.

Les avantages de ces deux méthodes de division sont :

- une relative simplicité de mise en œuvre ;
- un coût calculatoire très faible qui font qu'elles sont très souvent utilisées.

Ces méthodes présentent cependant un certain nombre de désavantages :

- elles sont peu robustes aux *outliers*. En effet, si des *outliers* sont présents dans l'ensemble des points traités alors des droites aberrantes vont apparaître pour les relier. C'est pour cela qu'une étape de *clustering*, même grossière avec un seuil fixe, est indispensable.
- ce sont des algorithmes récursifs qui nécessitent de connaître le dernier point de l'acquisition. Donc les traitements ne peuvent démarrer qu'après la fin de l'acquisition.
- la détermination du seuil demeure un problème. Si le seuil est grand, le processus d'extraction se termine trop rapidement, n'extrayant que peu de droites. A contrario, si le seuil est trop petit, on obtient de nombreux petits segments, qui seront potentiellement refusionner par l'étape de *merging*.

L'algorithme IEPF est certes plus simple et plus rapide puisque les paramètres des droites sont calculés à partir de deux points par une résolution simple d'un système d'équation. Cependant, une fois la procédure IEPF terminée, il faut connaître les imprécisions de ces paramètres pour procéder à

l'étape de fusion. Ils sont alors calculés par une minimisation quadratique sur l'ensemble des impacts de chaque segment extrait.

Algorithme 4 : Algorithme Split

Fonction $\text{Split}(\mathcal{T})$

Entrée : $\mathcal{T} \leftarrow \{t_1, \dots, t_n\}$

Mettre \mathcal{T} dans la liste \mathcal{L}

$S \leftarrow$ droite ajustée aux points de \mathcal{T} (par minimisation quadratique)

$t_{max} \leftarrow$ le point de \mathcal{T} avec la plus grande distance orthogonale entre d et S

Si $d > d_{max}$ **Alors**

$\mathcal{T}' \leftarrow \{t_1, \dots, t_{max}\}$

$\mathcal{T}'' \leftarrow \{t_{max}, \dots, t_n\}$

$\mathcal{L} \leftarrow \text{Split}(\mathcal{T}')$

$\mathcal{L} \leftarrow \text{Split}(\mathcal{T}'')$

$\mathcal{L} \rightarrow \mathcal{T}$

% éliminer \mathcal{T} de la liste \mathcal{L}

FinSi

Retourner \mathcal{L}

FinFonction

Algorithme 5 : Algorithme Merge

Fonction $\text{Merge}(\mathcal{L})$

Entrée : $\mathcal{L} \leftarrow$ liste des ensembles $\{\mathcal{T}_1, \dots, \mathcal{T}_k\}$

Pour $i = 1$ jusqu'à $k-1$ **faire**

Si \mathcal{T}_i et \mathcal{T}_{i+1} sont colinéaires (avec une marge d'erreur) **Alors**

$Q \leftarrow \mathcal{T}_i \cup \mathcal{T}_{i+1}$

$S \leftarrow$ droite ajustée aux points de Q par minimisation quadratique

$q_{max} \leftarrow$ le point de Q avec la plus grande distance orthogonale d à S

Si $d \leq d_{max}$ **Alors**

$\mathcal{L} \rightarrow \mathcal{T}_i$ et \mathcal{T}_{i+1}

% éliminer \mathcal{T}_i et \mathcal{T}_{i+1} de la liste \mathcal{L}

$\mathcal{L} \leftarrow Q$

% ajouter Q à la liste \mathcal{L}

FinSi

FinSi

FinPour

Retourner \mathcal{L}

FinFonction

L'algorithme de fusion (Algorithme 5), qui est utilisé lorsque les segments sont extraits, nécessite la connaissance des covariances sur les paramètres des droites obtenues. En effet, une méthode statistique classique, appelée « test du Chi-deux », est utilisée pour calculer les distances entre chaque paire de droites afin de déterminer si elles sont colinéaires ou non. Si deux droites ont une distance statistique inférieure à un seuil, alors elles sont fusionnées en une seule droite dont les nouveaux paramètres sont calculés à partir des impacts constituant les deux segments. La valeur du

seuil pour la distance statistique de la colinéarité est choisie égale à 2,77 (75% d'intervalle de confiance pour des variables à deux degrés de liberté).

III.5.2.3 Quelques autres algorithmes non implémentés

Nous allons présenter également quelques autres algorithmes rencontrés dans la littérature et qui sont réputés pour être robustes aux *outliers*. Ces algorithmes sont présentés dans [Nguyen, 2007]. Parce que ces méthodes qui nous semblent incompatibles avec les performances ce que l'on souhaite obtenir et pour des raisons que nous allons évoquer, nous ne les avons pas implémentées.

Algorithme basé sur la transformée de Hough

La transformée de Hough est couramment utilisée pour la recherche de formes (droites, ellipses...) en traitement des images. Cette transformation est également utilisée dans l'extraction des droites à partir d'acquisition issue d'un télémètre. Typiquement, il s'agit de transformer chaque point dans un espace discrétré des paramètres (ρ et θ) des droites potentielles pouvant passer par ce point. Ensuite, les accumulations les plus grandes, *i.e.* les candidats de l'espace discrétré qui ont reçu le plus de « votes » provenant des points, sont réputées pour correspondre à des droites.

Initialement, dans l'algorithme d'extraction basé sur la Transformée de Hough, les bruits et les imprécisions ne sont pas pris en compte pour le calcul des paramètres des droites. Il faut donc utiliser à nouveau une méthode de minimisation quadratique [Nguyen, 2007] pour déterminer ces paramètres et leur covariance.

La complexité $Comp_{Hough}$ de cette méthode dépend du nombre S de segments extraits à partir des $Nb_{impacts}$ impacts, de l'échantillonnage N_ρ en distance, de l'échantillonnage N_θ en angle. Cette complexité vaut $Comp_{Hough} = (S \times Nb_{impacts} \times N_\rho + S \times N_\theta \times N_\rho)$.

Il existe plusieurs désavantages pour lesquels cette approche nous semble difficilement exploitable dans notre cas :

- elle est relativement difficile à mettre en œuvre.
- il est difficile de choisir un bon échantillonnage de l'espace des paramètres. S'il est trop grand, la précision des droites extraites est mauvaise, s'il est trop petit, le temps de calcul augmente fortement. Il faut donc faire un compromis entre précision et rapidité.
- le coût calculatoire est de toute façon très élevé en raison de la complexité de l'algorithme. Ce problème de temps de calcul peut être en partie résolu en utilisant des variantes comme, par exemple la transformée Log-Hough [Giesler, 1998].
- il s'agit d'une approche récursive obligeant à attendre la fin de l'acquisition pour démarrer les traitements. De plus, il entraîne un double changement de coordonnées (polaire → cartésien, puis cartésien → polaire) avec des approximations pouvant entraîner une perte du caractère gaussien des paramètres et des imprécisions associées.

Algorithme RANSAC

Cet algorithme RANSAC (RANdom SAmple Consensus) est couramment utilisé pour des ajustements robustes à des modèles en présence d'*outliers*. La démarche est la suivante : on choisit aléatoirement deux points parmi l'ensemble des impacts à traiter. On calcule les paramètres de la droite passant par ces deux points et par calcul de la distance de chacun des autres impacts, on

associe les points (*inliers*) ayant une distance inférieure à un seuil. Si le nombre d'*inliers* est suffisant, alors on détermine les paramètres de la droite passant par ces points (par minimisation quadratique par exemple), et on recommence la procédure avec un nouvel ensemble de points (le précédent moins les *inliers*). On recommence tant que ce nombre d'*inliers* suffisant est atteint ou jusqu'à un nombre maximum de tentatives.

Le principal avantage de RANSAC est qu'il s'agit d'un algorithme générique pouvant être utilisé pour de nombreux modèles de primitives et qu'il est facile à mettre en œuvre. Cette méthode est aussi robuste puisqu'elle est justement construite pour n'être pas ou peu sensible aux *outliers*.

La complexité $Comp_{RANSAC}$ de cette méthode dépend du nombre S de segments extraits à partir des $Nb_{impacts}$ impacts et du nombre maximum d'essais Nb_{essais} pour obtenir le nombre suffisant d'*inliers*. Cette complexité vaut $Comp_{RANSAC} = S \times Nb_{impacts} \times Nb_{essais}$.

Les défauts que nous avons perçus et pour lesquels cet approche ne nous semble pas correspondre à nos attentes en performance sont :

- la faible quantité de points dans l'espace de recherche rend cette méthode peu rentable. Pour mettre un terme à l'algorithme, on impose un nombre maximum d'itération qui ne garantit pas toujours d'obtenir la solution avant d'atteindre cette limite.
- par le caractère aléatoire de la recherche de droites (sans tenir compte de l'aspect successif des impacts dans le balayage), on peut obtenir des droites qui n'ont pas d'existence réelle en termes d'obstacles présents dans la scène. Il est difficile de gérer ce problème.
- le coût calculatoire est très élevé si on veut obtenir une bonne segmentation, surtout si le nombre maximum d'itérations est déterminé élevé.
- la méthode oblige à attendre la fin de l'acquisition pour démarrer les traitements.

Algorithme EM (Expectation-Maximization)

L'algorithme EM est une méthode probabiliste communément utilisée dans les problèmes d'estimation de paramètres avec des variables manquantes. Les premières adaptations de cette méthode ont été faites dans le domaine de la vision artificielle. L'algorithme se déroule successivement en deux phases pour déterminer, par convergence, les paramètres d'une droite. Ces paramètres sont d'abord initialisés aléatoirement, puis par une première phase (*Expectation*) on calcule des poids déterminés à partir du modèle pour chacun des impacts. Dans une seconde phase (*Maximization*), on recalcule les paramètres de la droite afin d'obtenir une convergence des poids des points appartenant à la droite (*inliers*). Les paramètres de la droite sont alors déterminés une fois la convergence atteinte, si elle est atteinte.

La complexité $Comp_{EM}$ de cette méthode dépend du nombre S de segments extraits à partir des $Nb_{impacts}$ impacts, du nombre maximum d'essais de droites différentes $Nb_{droites}$ et du nombre d'itérations $Nb_{itérations}$ envisagées pour garantir la convergence. Cette complexité vaut $Comp_{EM} = S \times Nb_{impacts} \times Nb_{droites} \times Nb_{itérations}$.

Cette approche, très robuste aux *outliers*, n'est cependant, à notre sens, pas utilisable pour plusieurs raisons :

- la mise en œuvre n'est pas simple.

- elle ne garantit pas d’obtenir une solution et il est fréquent d’obtenir un minimum local pour la convergence et donc d’obtenir une mauvaise segmentation.
- cette méthode est extrêmement gourmande en temps de calcul. La complexité dépend fortement du nombre d’essais de droites différentes et du nombre d’itérations nécessaire à la convergence. De plus, elle nécessite un nombre élevé de calcul de paramètres de droites.
- cette méthode impose la fin de l’acquisition pour être initialisée.

III.5.3 Détermination des autres paramètres du segment

Le choix des autres paramètres utilisés pour la primitive « segment » se fait, en général, en fonction de l’utilisation que l’on souhaite faire des segments extraits. Les deux paramètres souvent choisis qu’il faudra déterminer, en plus bien sûr de l’orientation, sont soit les deux extrémités du segment, soit le milieu du segment associé à la longueur.

Une fois la segmentation effectuée, quelle que soit la méthode utilisée, chaque segment extrait est alors déterminé par l’ensembles des impacts (*inliers*) appartenant au segment ainsi que par la droite support, exprimée par les paramètres (ρ_d et θ_d) et les imprécisions associées exprimées par une matrice de covariance :

$$\text{cov}_{\text{droite support}} = \begin{pmatrix} \sigma_{\rho_d}^2 & \sigma_{\rho_d \theta_d} \\ \sigma_{\theta_d \rho_d} & \sigma_{\theta_d}^2 \end{pmatrix}$$

Le calcul des paramètres supplémentaires ne pose pas de problème, au contraire du calcul des imprécisions, qui est souvent fastidieux au regard des expressions obtenues pour ces paramètres. Nous avons plutôt opté pour un bornage de ces erreurs, qui nous place dans le cas le plus défavorable pour les imprécisions, et de l’utilisation que nous allons en faire par la suite, mais qui évite de lourds calculs. De plus, nous verrons que pour certains paramètres (le milieu, en particulier) il est difficile de traiter le problème en coordonnées polaires.

III.5.3.1 Calcul des extrémités du segment

Après la segmentation, les points appartenant au segment sont issus du balayage du télémètre. Nous appelons $t_{ext_1} = (\rho_{ext_1}, \theta_{ext_1})$ et $t_{ext_2} = (\rho_{ext_2}, \theta_{ext_2})$ respectivement le premier et le dernier impact de cet ensemble qui sont naturellement les extrémités de ce segment. Ces impacts ont très peu de chance d’être sur la droite extraite. De manière à obtenir les extrémités $t_1 = (\rho_1, \theta_1)$ et $t_2 = (\rho_2, \theta_2)$ du segment, on projette orthogonalement les impacts t_{ext_1} et t_{ext_2} sur la droite support. Les coordonnées de ces impacts t_1 et t_2 projetés sont alors :

$$\begin{cases} \rho_1 = \sqrt{\rho_d^2 + \rho_{ext_1}^2 \sin^2(\theta_d - \theta_{ext_1})} \\ \theta_1 = \theta_d - \arctg \frac{\rho_{ext_1} \sin(\theta_d - \theta_{ext_1})}{\rho_d} \end{cases} \text{ et } \begin{cases} \rho_2 = \sqrt{\rho_d^2 + \rho_{ext_2}^2 \sin^2(\theta_d - \theta_{ext_2})} \\ \theta_2 = \theta_d - \arctg \frac{\rho_{ext_2} \sin(\theta_d - \theta_{ext_2})}{\rho_d} \end{cases}$$

Avec les précautions d’usage pour la détermination de la tangente (on rappelle que l’on souhaite que les angles θ soient tels que $0 \leq \theta \leq \pi$)

Au regard de ces expressions, les imprécisions sont délicates à exprimer. Nous avons préféré donner une borne supérieure pour ces erreurs, qui conduira évidemment au cas le plus défavorable lors de

l'utilisation de ces paramètres dans la suite de notre processus de suivi, mais qui n'obligera pas à des calculs trop lourds. De plus, nous verrons que le bornage de ces erreurs n'entraîne pas de perturbations dans le processus de suivi. Nous n'indiquons les imprécisions que pour l'une des extrémités, en l'occurrence t_1 :

$$\text{cov}_{t_1} = \begin{pmatrix} \sigma_{\rho_1}^2 & \sigma_{\rho_1 \theta_1} \\ \sigma_{\theta_1 \rho_1} & \sigma_{\theta_1}^2 \end{pmatrix} = \begin{pmatrix} (\sigma_{\rho_d} + \sigma_{\rho_{extl}})^2 & \sigma_{\rho_d \theta_d} \\ \sigma_{\theta_d \rho_d} & \sigma_{\theta_d}^2 \end{pmatrix} = \begin{pmatrix} (\sigma_{\rho_d} + \sigma_{\rho})^2 & \sigma_{\rho_d \theta_d} \\ \sigma_{\theta_d \rho_d} & \sigma_{\theta_d}^2 \end{pmatrix},$$

en prenant $\sigma_{\theta_{extl}}$ négligeable ou nul et $\sigma_{\rho_{extl}} = \sigma_{\rho}$, l'écart-type des erreurs de mesures identique quel que soit l'impact.

III.5.3.2 Calcul de la longueur du segment

Pour retrouver la longueur d'un segment extrait, on calcule la distance euclidienne entre les deux extrémités projetées sur la droite. On voit donc que le calcul des projections est indispensable, même si les extrémités ne sont pas choisies comme paramètres de représentation du segment. On a donc :

$$\text{longueur} = \sqrt{(\rho_1 \cos \theta_1 - \rho_2 \cos \theta_2)^2 + (\rho_1 \sin \theta_1 - \rho_2 \sin \theta_2)^2}$$

En fait, cette longueur peut-être calculée, sans approximation, en coordonnées cartésiennes :

$$\text{longueur} = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2}$$

En reportant les imprécisions en distance de chacune des extrémités, l'imprécision sur la longueur sera alors choisie (bornée) par :

$$\sigma_{\text{longueur}} = \sigma_{\rho_1} + \sigma_{\rho_2}$$

III.5.3.3 Calcul du milieu du segment

Il faut tout d'abord insister sur le fait que le milieu du segment détecté ne correspond pas au point central de l'ensemble des *inliers* du segment (sauf cas très particulier). Le centre du segment sera obtenu par le calcul du milieu des deux extrémités projetées, et se trouvera alors bien sur la droite support. Le calcul en polaire de ce milieu est délicat. Il peut cependant être obtenu, de manière approchée, en imaginant que le milieu est le point de tangence (situé sur la droite support) de deux cercles centrés sur les points extrémités. Soit $M = (\rho_M, \theta_M)$ le centre du segment, ce point vérifie alors l'équation :

$$\frac{\cos(2\theta_M - \theta_1 - \theta_d)}{\cos(2\theta_M - \theta_2 - \theta_d)} - \frac{\rho_1}{\rho_2} = 0 \quad (5)$$

On peut résoudre l'équation non linéaire (5) par variations successives de θ_M et en respectant un critère d'arrêt en précision (en réduisant la zone de recherche à $0 < \theta_M < \pi$). ρ_M se retrouve alors facilement puisque M est situé sur la droite support.

Mais il s'agit alors d'une solution approchée, et nous avons préféré exprimer le centre du segment en coordonnées cartésiennes $M = (x_M, y_M)$, puis de repasser éventuellement en coordonnées polaires :

$$\begin{cases} x_M = \frac{\rho_1 \cos \theta_1 + \rho_2 \cos \theta_2}{2} \\ y_M = \frac{\rho_1 \sin \theta_1 + \rho_2 \sin \theta_2}{2} \end{cases} \Rightarrow \begin{cases} \rho_M = \sqrt{x_M^2 + y_M^2} \\ \theta_M = \arctg \frac{y_M}{x_M} \text{ (avec } 0 \leq \theta_M \leq \pi) \end{cases}$$

Les bornes des imprécisions seront obtenues en reportant celles des points extrémités et sont obtenues par la matrice de covariance :

$$\text{cov}_M = \begin{pmatrix} \sigma_{\rho_M}^2 & \sigma_{\rho_M \theta_M} \\ \sigma_{\theta_M \rho_M} & \sigma_{\theta_M}^2 \end{pmatrix} = \begin{pmatrix} 4(\sigma_{\rho_d} + \sigma_{\rho})^2 & 4\sigma_{\rho_d \theta_d} \\ 4\sigma_{\theta_d \rho_d} & 4\sigma_{\theta_d}^2 \end{pmatrix}$$

III.5.4 Modélisation par des primitives de type rectangle

Beaucoup de travaux utilisent les primitives de type segment pour la segmentation de données télémétriques, mais la plupart traitent de la localisation de robots mobiles se déplaçant dans un environnement certes inconnu, mais très structuré, comme c'est le cas pour le SLAM (*Simultaneous Localization And Mapping*). Comme il n'y a pas (ou peu) d'autres objets mobiles dans la scène, la carte de l'environnement, alors modélisée par des segments, est souvent correctement construite et cette modélisation se justifie pleinement.

Dans le cas plus complexe de suivi d'objets mobiles, avec le capteur lui-même en mouvement, l'utilisation des segments comme mesures de l'environnement peut entraîner quelques difficultés. En effet, le suivi impose une comparaison entre ce que l'on connaît de l'environnement à un instant (celui précédent la segmentation) et ce que l'on découvre à l'instant de la segmentation. Si pour diverses raisons (objet en bord de zone d'observation, occultations par d'autres objets...), la forme perçue de l'objet change, alors cette association sera d'autant plus difficile. C'est pour cela qu'il faut choisir un modèle de l'objet dont les paramètres sont le moins possible sensibles à ces changements de forme [MacLachlan, 2006]. Une illustration de cette problématique est donnée sur la figure 60.

On voit donc que pour certains cas, le centre du segment et/ou les extrémités sont très sensibles à ces changements de forme. Ceci peut entraîner l'apparition de mouvements parasites lors de l'estimation du mouvement des objets suivis. On peut noter que si on choisit le centre de gravité de l'ensemble des points (après *clustering*), cet inconvénient devient très délicat à traiter.

Afin de résoudre ce problème, nous considérons que les mesures appartenant à un objet peuvent être modélisé par un rectangle. Il s'agit d'une bonne représentation des objets que l'on doit suivre (*i.e.* des véhicules). Les paramètres de ce modèle seront le centre et l'orientation du rectangle, ainsi que sa longueur et sa largeur. Cependant, les objets suivis peuvent être de différentes tailles, même si ce sont tout de même des véhicules (camions, camionnettes, vans, grandes voitures, petites voitures...) et dont les dimensions du modèle peuvent varier en fonction de l'objet suivi. Afin de donner la bonne dimension au modèle rectangle, il serait nécessaire de reconnaître l'objet avant de le modéliser. Cette procédure de reconnaissance est difficilement réalisable avec les mesures télémétriques seules et il serait indispensable d'ajouter d'autres informations sur les objets provenant par exemple d'un autre capteur. Une caméra CCD et les traitements associés pourraient en partie résoudre ce problème de classification.

En ce qui nous concerne, en raison du contexte applicatif autoroutier étudié, nous n'avons choisi qu'un seul type d'objet à suivre, à savoir les voitures, dont les dimensions, la longueur L_{rect} et la largeur l_{rect} sont déterminées en faisant une moyenne des tailles des voitures les plus couramment rencontrées et obtenues à partir des données constructeurs.

On cherche alors à ajuster (*fit*) un rectangle de ces dimensions aux segments extraits de l'étape précédente. Deux cas peuvent se produire :

- deux segments consécutifs forment un coin,
- le segment est isolé.

Il faut alors détecter la présence d'éventuels coins à partir de l'ensemble des segments.

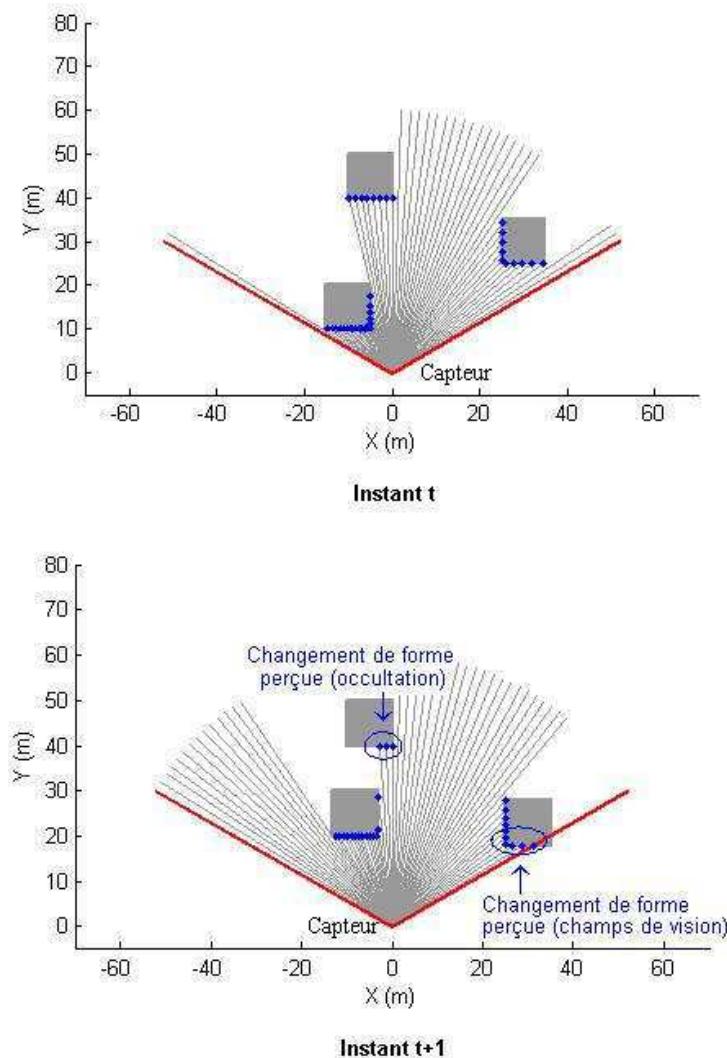


Figure 60 : Illustration des changements de formes perçues des objets entre deux instants.

III.5.4.1 Détection des coins

Un coin est l'intersection de deux segments consécutifs qui forment un angle $b=90^\circ$ (avec une tolérance de $\pm 15^\circ$ pour intégrer les erreurs d'orientation de chacun des deux segments). On notera que trouver les coordonnées polaires de l'intersection de deux segments (exprimés en polaire) est

délicat et qu'on ne peut obtenir qu'une solution approchée par variations successives. Il est préférable de calculer les coordonnées des intersections en cartésien, pour revenir ensuite en coordonnées polaires.

Soit $Coin = (x_{coin}, y_{coin})$ le coin situé à l'intersection de deux segments consécutifs dont les équations des droites supports sont exprimées, en cartésien, par $y = a_1 \cdot x + b_1$ et $y = a_2 \cdot x + b_2$. On a alors :

$$\begin{cases} x_{coin} = \frac{b_2 - b_1}{a_1 - a_2} \\ y_{coin} = a_1 \cdot \frac{b_2 - b_1}{a_1 - a_2} + b_1 \end{cases} \Rightarrow \begin{cases} \rho_{coin} = \sqrt{x_{coin}^2 + y_{coin}^2} \\ \theta_{coin} = \arctg \frac{y_{coin}}{x_{coin}} \text{ (avec } 0 \leq \theta_{coin} \leq \pi) \end{cases}$$

L'erreur, exprimée par la matrice de covariance cov_{coin} sera approchée par une borne en reportant les erreurs sur les extrémités des segments proches du coin, soit t_2 du segment₁ et t_1 segment₂. Il s'agit certes d'une approximation mais qui donne un bon ordre de grandeur de l'erreur sur la position du coin :

$$\text{cov}_{coin} = \begin{pmatrix} \sigma_{\rho_{coin}}^2 & \sigma_{\rho_{coin}\theta_{coin}} \\ \sigma_{\theta_{coin}\rho_{coin}} & \sigma_{\theta_{coin}}^2 \end{pmatrix}$$

$$\text{cov}_{coin} = \begin{pmatrix} (\sigma_{\rho_d, segment_1} + \sigma_{\rho_d, segment_2} + 2\sigma_{\rho})^2 & (\sqrt{\sigma_{\rho_d\theta_d, segment_1}} + \sqrt{\sigma_{\rho_d\theta_d, segment_2}})^2 \\ (\sqrt{\sigma_{\rho_d\theta_d, segment_1}} + \sqrt{\sigma_{\rho_d\theta_d, segment_2}})^2 & (\sigma_{\theta_d, segment_1} + \sigma_{\theta_d, segment_2})^2 \end{pmatrix}.$$

III.5.4.2 Modélisation par un rectangle

Pour modéliser les segments par des rectangles, on traite en priorité les coins.

Lorsqu'un coin est détecté, on place le modèle rectangle en prenant ce coin comme référence. L'orientation du rectangle est celle du plus grand des deux segments (le plus grand segment est choisi naturellement comme la longueur du véhicule). L'orientation du véhicule, avec l'imprécision associée, est donc directement celle de ce segment. Le centre du rectangle est calculé à partir du coin (figure 61). On a donc les paramètres et les imprécisions associées :

$$\begin{cases} \text{orientation : } \theta_{rect} = \theta_d \text{ du segment le plus long} \\ \text{centre : } x_{rect} = x_{coin} + 1/2 \text{ diagonale} \\ \quad y_{rect} = y_{coin} + 1/2 \text{ diagonale} \\ \text{longueur : } L_{rect} \\ \text{larguer : } l_{rect} \end{cases} \quad \text{avec} \quad \begin{cases} \sigma_{\theta_{rect}} = \sigma_{\theta_d} \text{ du segment le plus long} \\ \sigma_{x_{rect}} = \sigma_{x_{coin}} \\ \sigma_{y_{rect}} = \sigma_{y_{coin}} \\ \sigma_{L_{rect}} = 0 \\ \sigma_{l_{rect}} = 0 \end{cases}$$

On traite ensuite les segments isolés. Il est fréquent d'obtenir des segments seuls (*i.e.* ne formant pas un coin avec un autre segment) en raison de la position du véhicule qui fait qu'un seul côté est visible par le capteur ou éventuellement en raison d'une mauvaise détection sur l'un des côtés. Il s'agit alors de s'appuyer sur ce segment pour placer le rectangle (figure 61). L'important est de savoir quel côté du véhicule est détecté. On le détermine par de simples hypothèses :

- si $\text{longueur du segment} > l_{rect}$ alors ce segment est la longueur du rectangle ;
- si $\text{longueur du segment} \leq l_{rect}$ alors ce segment est la largeur du rectangle.

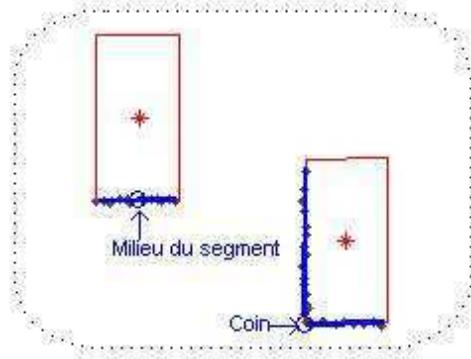


Figure 61 : Modélisation par des rectangles.

L’orientation du rectangle est donné par l’orientation du segment si c’est le segment correspond à la longueur. Si c’est une largeur, il faut ajouter $\pi/2$ à l’orientation du segment (en veillant à avoir $0 \leq \text{orientation} \leq \pi$). Les coordonnées du centre du rectangle sont obtenues à partir des coordonnées du milieu du segment en ajoutant soit une demi-longueur, soit une demi-largeur. On a alors les paramètres et les imprécisions associées :

$$\begin{cases} \text{orientation: } \theta_{\text{rect}} = \theta_d \text{ du segment} & \text{ou} & \theta_{\text{rect}} = \theta_d \text{ du segment} + \pi/2 \\ \text{centre: } x_{\text{rect}} = x_{\text{centre}} + 1/2 \text{ largeur} & \text{ou} & x_{\text{rect}} = x_{\text{centre}} + 1/2 \text{ longueur} \\ & & y_{\text{rect}} = y_{\text{centre}} + 1/2 \text{ longueur} \text{ ou } x_{\text{rect}} = x_{\text{centre}} + 1/2 \text{ largeur} \\ \text{longueur: } L_{\text{rect}} \\ \text{larguer: } l_{\text{rect}} \end{cases},$$

et les imprécisions sur ces paramètres sont calculées à partir des covariances des paramètres dont le rectangle modèle est issu.

III.6 Une nouvelle méthode de segmentation

Nous avons développé un algorithme de segmentation, basé sur la détection de segments et de coins, à partir des coordonnées des mesures exprimées en coordonnées capteur (ρ, θ) . Cette approche, adaptée d’un algorithme de segmentation pour la détection de droites dans un environnement intérieur structuré [Alempijevic, 2004], utilise un paramètre invariant, solution d’une équation bâtie à partir d’un ensemble de mesures consécutives et susceptibles d’appartenir à une même droite. Nous allons présenter dans la suite cette méthode de segmentation mais nous pouvons déjà dire quels sont ses attraits majeurs :

- elle ne nécessite pas de *clustering* préalable. En fait, nous le verrons, le *clustering* est inclus dans la méthode ;
- les calculs s’effectuent en coordonnées polaires, évitant une transformation en coordonnées cartésiennes des mesures télémétriques, et ainsi une modification des statistiques de bruits de mesure ;
- la séparation des mesures en groupes, pouvant être perçus comme des *clusters*, s’effectue récursivement. Le seuil qui est utilisé pour séparer les impacts n’est pas lié à la distance

euclidienne entre les points mais à leur distance angulaire. De plus, ce seuil est indépendant de l'orientation de la surface visée et peut être évalué en incluant les imprécisions sur les mesures ;

- elle permet de modéliser par des droites des courbes avec de faible courbure. Ce défaut relatif de la méthode peut être perçu comme un atout lorsqu'il s'agit de modéliser, par des segments, les cotés d'un véhicules qui sont rarement rectilignes ;
- elle est robuste aux *outliers*, précises dans la détection et relativement peu gourmande en temps de calcul.

Cette méthode est basée sur une propriété invariante des mesures télémétriques qui appartiennent à une même droite (ou une courbe proche d'une droite). Nous allons mettre en évidence l'invariant puis présenter les différentes étapes de l'algorithme sur des données non bruitées pour apporter ensuite les modifications lorsqu'il s'agit de segmenter des mesures bruitées.

III.6.1 Mise en évidence d'un invariant

Soient trois impacts $\{t_{i-1}, t_i, t_{i+1}\}$ consécutifs issus d'un même balayage, où $t_i = (\rho_i, \theta_i)$. Si le télémètre vise une surface plane, alors ces trois impacts appartiennent naturellement à une même droite (figure 62).

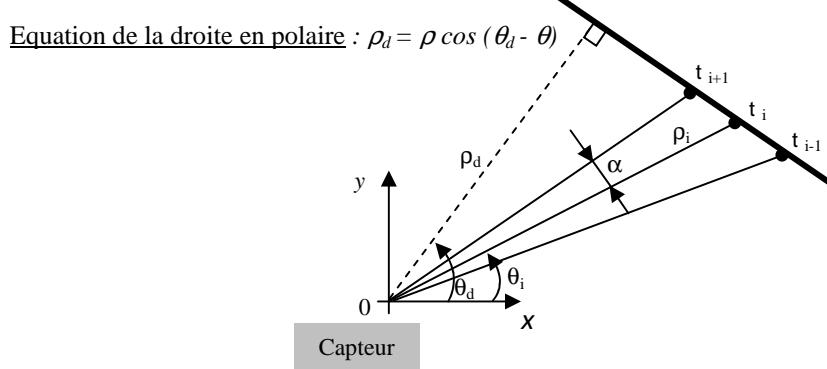


Figure 62 : Trois impacts consécutifs issus d'une surface plane.

On peut alors écrire, pour les impacts $\{t_{i-1}, t_i, t_{i+1}\}$ appartenant à la droite :

$$\rho_j = \frac{\rho_d}{\cos(\theta_d - \theta_i - (j-i)\alpha)} \quad \text{pour } j \in \{i-1, i, i+1\} \quad (6)$$

Soit un terme $S_{i,1}$, calculé pour l'impact t_i et pour un voisinage 1 (on considère l'impact précédent et l'impact suivant) tel que :

$$S_{i,1} = \frac{\frac{1}{\rho_{i-1}} + \frac{1}{\rho_i} + \frac{1}{\rho_{i+1}}}{\frac{1}{\rho_i}} \quad (7)$$

D'après (6), on peut obtenir une valeur pour $S_{i,1}$ donnée en (7) qui ne dépend plus que de la résolution angulaire α . Nous appelons $S_{i,théorique}$ cette valeur, donnée par :

$$S_{i,\text{théorique}} = \frac{\cos(\theta_d - \theta_i + \alpha) + \cos(\theta_d - \theta_i) + \cos(\theta_d - \theta_i - \alpha)}{\cos(\theta_d - \theta_i)} = 1 + 2 \cos \alpha \quad (8)$$

On peut donc dire que si trois impacts consécutifs, centrés sur l'impact t_i , appartient à une droite, la valeur de $S_{i,1}$, calculée par (7), est une constante dépendante de la résolution angulaire fixée. Cette grandeur est donc invariante pour trois points quel que soit l'endroit où ils sont situés dans l'espace.

Généralisons maintenant pour un voisinage quelconque, que nous appelons *voisinage*, autour de l'impact t_i . Le terme $S_{i,\text{voisinage}}$, qui prend en compte $(2 * \text{voisinage} + 1)$ impacts est alors :

$$S_{i,\text{voisinage}} = \frac{\sum_{j=-\text{voisinage}}^{\text{voisinage}} \frac{1}{\rho_{i+j}}}{\frac{1}{\rho_i}} \quad (9)$$

$$S_{i,\text{voisinage}} = \frac{\cos(\theta_d - \theta_i + \text{voisinage} * \alpha) + \dots + \cos(\theta_d - \theta_i) + \dots + \cos(\theta_d - \theta_i - \text{voisinage} * \alpha)}{\cos(\theta_d - \theta_i)}$$

Et nous obtenons une valeur $S_{\text{voisinage},\text{théorique}}$ invariante, dépendant uniquement de la résolution angulaire α et du nombre de voisins autour de l'impact considéré, donnée par :

$$S_{\text{voisinage},\text{théorique}} = 1 + 2 \sum_{j=1}^{Nb_voisin} \cos j \alpha \quad (10)$$

III.6.2 Principe de la méthode de segmentation

III.6.2.1 Segmentation par recherche d'invariants

La méthode de segmentation en droite est basée sur le principe des invariants présenté en (10). En effet, en l'absence de bruit, un ensemble de $(2 * \text{voisinage} + 1)$ impacts consécutifs, centré autour de l'impact t_i , appartient à une droite si :

$$S_{i,\text{voisinage}} = \frac{\sum_{j=-\text{voisinage}}^{\text{voisinage}} \frac{1}{\rho_{i+j}}}{\frac{1}{\rho_i}} = S_{\text{voisinage},\text{théorique}} = 1 + 2 \sum_{j=1}^{\text{voisinage}} \cos j \alpha \quad (11)$$

On montre sur la figure 63, l'évolution de $S_{\text{voisinage},\text{théorique}}$ en fonction du nombre d'impacts considéré $(2 * \text{voisinage} + 1)$ et de la résolution angulaire, pour les résolutions angulaires du télémètre, *i.e.*

$\alpha = \{0,25^\circ ; 0,5^\circ ; 1^\circ\}$. On peut remarquer que le rapport $\frac{S_{\text{voisinage},\text{théorique}}}{2 * \text{voisinage} + 1}$ (donné par la pente des courbes) reste très proche de 1 quel que soit α . On pourra donc, si nécessaire, approcher simplement l'invariant par le nombre d'impacts. Par exemple, pour la résolution la plus grande ($\alpha=1^\circ$) et pour un voisinage de 30 points, soient 61 impacts, l'erreur commise dans l'approximation sera inférieure à 5%.

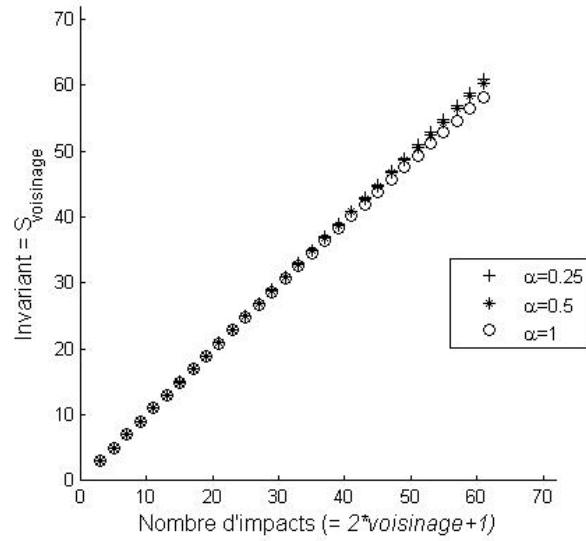


Figure 63 : Evolution de l'invariant théorique en fonction du nombre d'impacts.

Nous montrons les évolutions des invariants $S_{i,5}$ et $S_{i,10}$ sur les figure 65 et figure 66 calculées pour les mesures télémétriques synthétiques du balayage de la figure 64. Pour bien voir la correspondance entre les impacts et les valeurs de $S_{i,5}$ et $S_{i,10}$, nous avons mis en évidence deux objets (un obstacle et un véhicule).

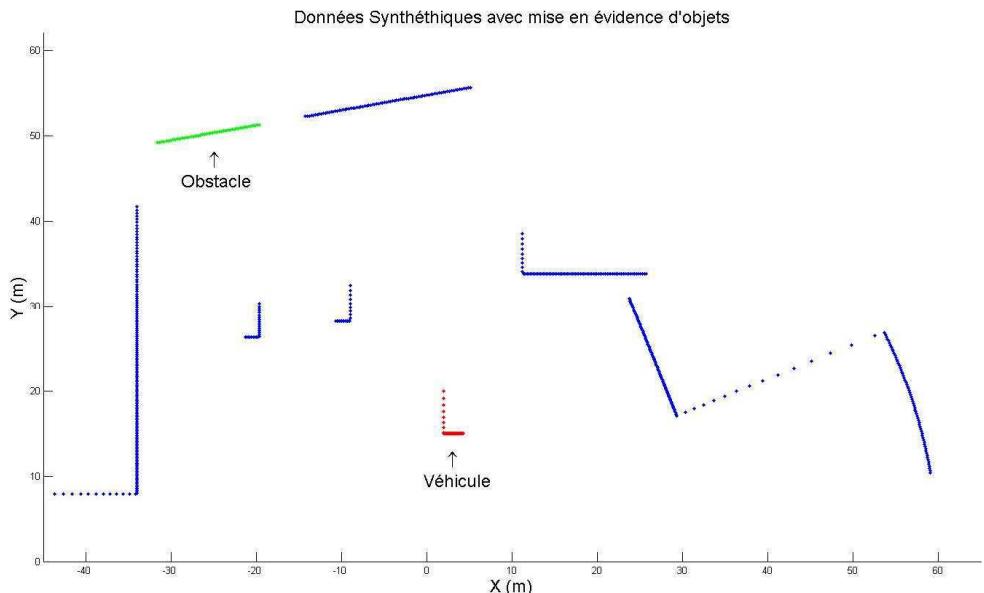


Figure 64 : Mesures télémétriques synthétiques non bruitées issues d'un simulateur.

Afin de répondre à l'objectif de la segmentation des mesures télémétriques, nous devons déterminer la plus longue suite d'impacts consécutifs. Il faut donc trouver des successions de $(2*voisinage + 1)$ impacts centrés autour d'impacts t_i , dont les termes $S_{i,voisinage}$ sont proches de l'invariant théorique $S_{voisinage \text{ théorique}}$.

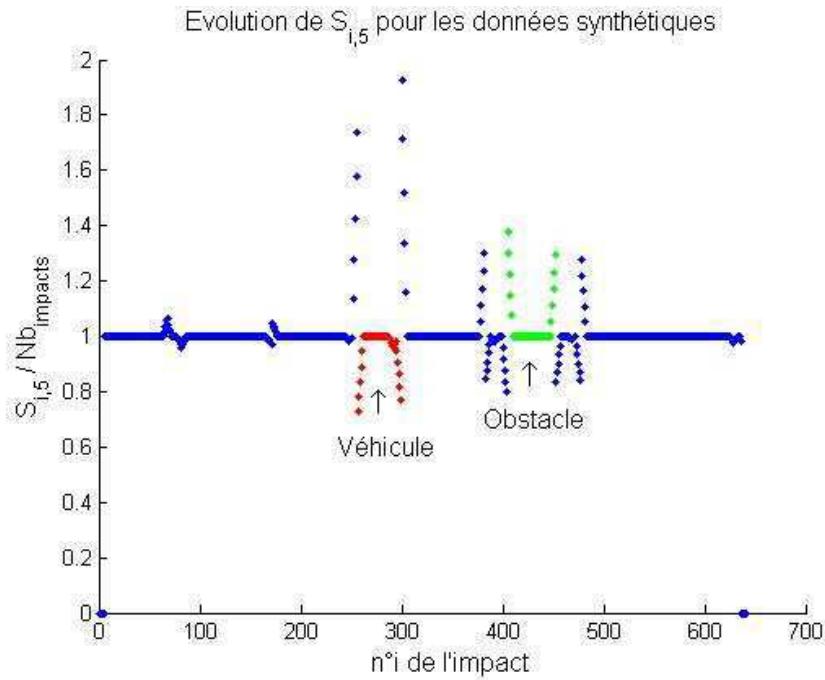


Figure 65 : Evolution de $S_{i,5}$ pour les mesures télémétriques de la figure 64.

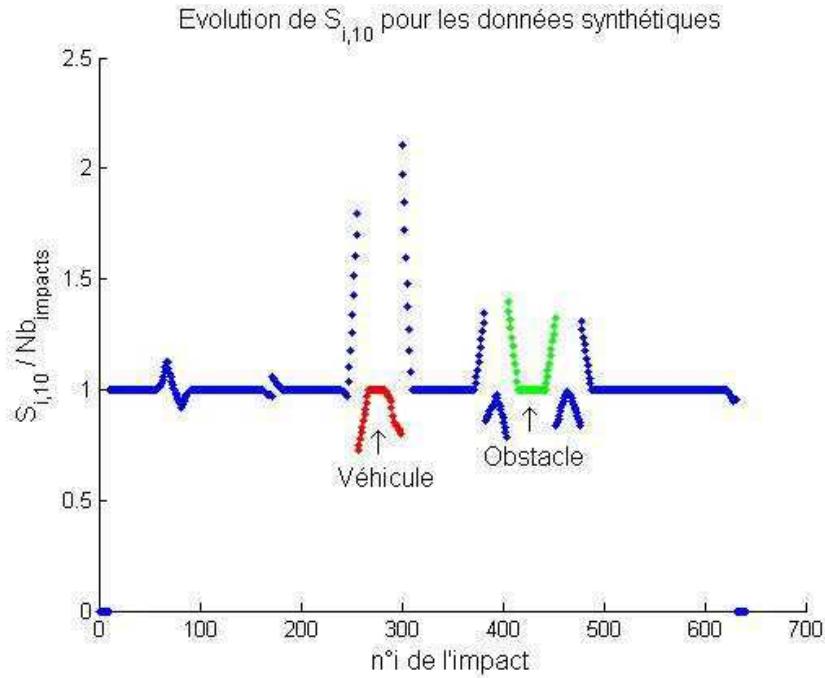


Figure 66 : Evolution de $S_{i,10}$ pour les mesures télémétriques de la figure 64.

La première étape de cette segmentation est le calcul, pour un voisinage choisi et pour chacun des impacts t_i du balayage, de l'écart entre $S_{i,voisinage}$ et l'invariant théorique $S_{voisinage,\text{théorique}}$. Si cet écart est inférieur à un seuil, alors un groupe de $(2*voisinage + 1)$ impacts passe par une droite et forme un segment. Ce groupe d'impacts, répondant au critère de ressemblance à l'invariant, peut être perçu comme un *cluster local* puisque, bien qu'il fasse référence à un critère de ressemblance (c'est la définition du *cluster*), ce regroupement est aussi déterminé en fonction de l'impact central t_i . Nous avons préféré utiliser une autre dénomination, et appeler ces groupes des *accumulations* pour rappeler les accumulateurs des méthodes de Hough, puisque pour chacun des impacts nous aurons

un certain nombre de groupement locaux dont la taille varie en fonction du voisinage. On peut remarquer que ces accumulations comportent toujours un nombre impair d'impacts.

En l'absence de bruit, les termes $S_{i,voisinage}$ seront égaux à la valeur théorique $S_{voisinage_{théorique}}$, l'écart sera donc nul.

Nous apportons tout d'abord quelques précisions sur cet algorithme de segmentation :

- le balayage comporte $MaxImpacts$ impacts (cf. Tableau 10).
- pour chacun des impacts t_i , l'algorithme recherche récursivement d'éventuelles *accumulations* de taille croissante. Il commence avec un *voisinage* égal à 1, c'est-à-dire 2 voisins et des *accumulations* de 3 points successifs. La recherche d'*accumulations* s'arrête pour un voisinage fixé à *Max_voisinage*, fixé dans un premier temps à $(MaxImpacts/2)$, qui est le cas extrême où tous les impacts forment une droite. Pour limiter le coût calculatoire, le critère d'arrêt peut être fixé à $Max_voisinage = 20$ (i.e. les droites sont formées au maximum de 41 impacts successifs), qui semble une taille raisonnable au vu des mesures traitées. Si les segments réels sont plus longs, et donc séparés en plus petits segments, la procédure de *merging* qui suivra ne manquera pas de les fusionner.
- l'algorithme s'arrêtera également lorsque, pour un *voisinage* considéré (et de taille inférieure à *Max_voisinage*), il n'y a pas d'*accumulations*. De toute manière, pour les voisinages de taille supérieure, il n'y aura plus d'*accumulations*.
- les invariants $S_{voisinage_{théorique}}$, qui ne dépendent que de la taille du *voisinage* et de la résolution angulaire, peuvent être calculés au préalable en dehors de la boucle de l'algorithme, limitant ainsi les temps de calcul.

L'algorithme de recherche d'*accumulations* par comparaison aux invariants est présenté en pseudo-code (Algorithme 6).

A l'issue de cette procédure on obtient des valeurs d'*accumulations* pour chacun des impacts du balayage. Sur la figure 67, nous représentons la valeur de l'*accumulation* la plus grande, obtenue pour chacun des impacts du balayage de la figure 64 (les deux objets précédemment mis en évidence apparaissent encore). Nous rappelons que le balayage se fait dans le sens trigonométrique, donc l'impact n°1 est situé à droite de la figure.

Avec cette évolution des *accumulations* maximales nous pouvons obtenir directement les extrémités des segments de la scène. Cette méthode de segmentation s'apparente donc plus à une technique de *détection de ruptures*, mais sans calcul préalable des paramètres de la droite support comme on peut le faire, par exemple, avec des méthodes basées sur le filtre de Kalman [Roumeliotis, 2000].

Cette représentation des *accumulations* maximales montre des pics qui correspondent aux segments présents dans les mesures. La détermination de certaines valeurs de ces pics (hauteur, base, n° de l'impact de début et de fin) permettra alors d'extraire certains des paramètres de ces segments. Plusieurs remarques s'imposent :

- dans le repère considéré pour la représentation des *accumulations*, les pics forment des triangles de pente (+1) ou (-1) ;

- le nombre d’impacts appartenant au segment est toujours impair est le sommet du triangle représente l’impact central de l’accumulation correspondant au segment détecté. Dans de très rares cas, cet impact central correspond au milieu du segment ;
- les points extrêmes du segment sont également connus et sont repérés par les numéros des impacts à la base du triangle.

Algorithme 6 : Algorithme par recherche d’invariants

```

Entrée : un ensemble d’impacts  $T \leftarrow \{t_1, \dots, t_{MaxImpacts}\}$ 
 $Flag\_accum \leftarrow 1$  % flag de fin d’accumulation
 $Max\_voisinage \leftarrow 20$  % taille maxi des accumulations
Calculer les  $S_{voisinage_{théorique}} = 1 + 2 \sum_{j=1}^{voisinage} \cos j \alpha$  pour  $voisinage$  de 1 à  $Max\_voisinage$ 
 $Acc(1 \text{ à } MaxImpacts) \leftarrow 0$  % création un tableau d’accumulations,
TantQue  $Flag\_accum=1$  faire
  Pour  $voisinage$  de 1 à  $Max\_voisinage$  faire
     $Flag\_accum \leftarrow 0$ 
    Pour  $k$  de 1 à  $voisinage$  faire
       $Acc(k) = S_{k,voisinage} = 0$  % pas d’accumulations possibles avant  $voisinage$ 
    FinPour
    Pour  $k$  de 1+  $voisinage$  à  $MaxImpacts$  faire
      Calculer  $S_{k,voisinage}$ 
      Si  $S_{k,voisinage} = S_{voisinage_{théorique}}$  Alors
         $Acc(k) = voisinage$ 
         $Flag\_accum \leftarrow 1$  % il y a eu accumulation pour ce  $voisinage$ 
      FinSi
    FinPour
    Pour  $k$  de  $(MaxImpacts - voisinage)$  à  $MaxImpacts$  faire
       $Acc(k) = S_{k,voisinage} = 0$  % plus d’accumulations possibles avant
    FinPour
  FinPour
FinTantQue

```

Pour obtenir ces paramètres du segment, il faut donc détecter ces pics. Une procédure basée sur la transformée de Hough, et plus précisément la transformée Log-Hough, est présentée dans [Alempijevic, 2004]. Mais, vu la simplicité de la forme recherchée, c’est-à-dire un triangle dont on connaît les dimensions, à savoir la base vaut deux fois la hauteur, une solution basée sur la transformée de Hough semble inutile et sera coûteuse en temps de calcul. Nous avons opté pour une solution simple et itérative afin de faire correspondre des triangles aux pics obtenus lors de la représentation des *accumulations* maximales, en se basant essentiellement sur la hauteur des pics. Les triangles ainsi obtenus permettent de connaître les extrémités des segments en coordonnées polaires et l’ensemble des impacts appartenant au segment.

Les résultats obtenus sont donnés sur la figure 68. La détection des segments est tout à fait correcte et en plus rapide. On peut remarquer que les premiers impacts (à droite) de la figure 64 forment une surface légèrement courbée. La procédure détecte alors une succession de segments (*cf.* les petits triangles à gauche de la figure 68) de manière à « coller » au mieux à cette surface.

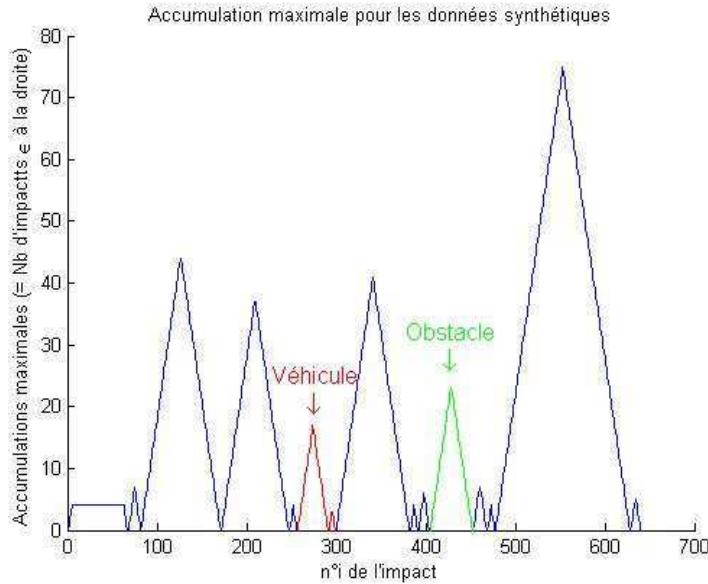


Figure 67 : Evolution des accumulations pour les mesures de la figure 64.

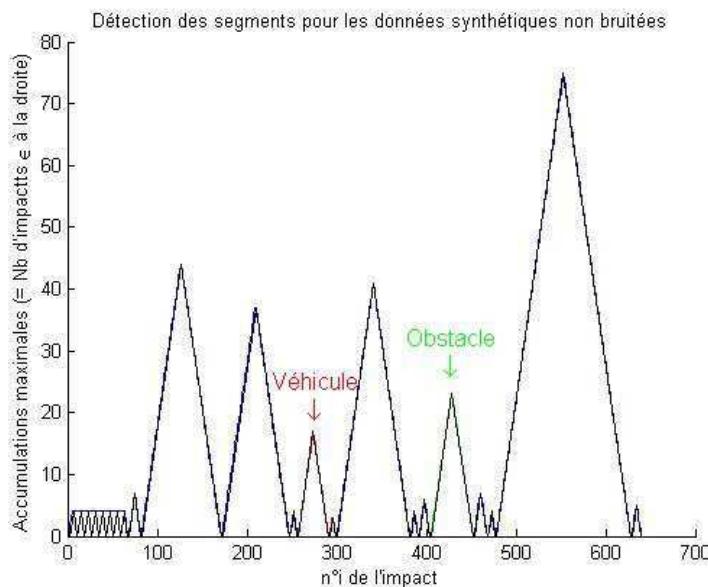


Figure 68 : Détection des pics par recherche de triangles.

Pour des données bruitées, cette détection de pics devra être légèrement modifiée puisque les pics auront certes encore une forme triangulaire, mais il y aura des impacts manquant dans les contours de la forme.

Nous allons voir comment, à partir de la représentation en triangle de ces pics d'accumulations maximales, nous retrouvons les paramètres des segments associés.

III.6.2.2 Extraction des paramètres des segments

Calcul de l'orientation θ_d de la droite issue des accumulations

Pour calculer l'orientation des droites supportant les segments, nous repartons des *accumulations* et nous introduisons, pour chaque impact t_i , un nouveau terme $S'_{i,voisinage}$, tel que :

$$S'_{i,voisinage} = \frac{- \sum_{j=i-voisinage}^{i-1} \frac{1}{\rho_j} + \sum_{j=i+1}^{i+voisinage} \frac{1}{\rho_j}}{\frac{1}{\rho_i}} = \sum_{j=i-voisinage}^{i+voisinage} \text{sign}(j-i) \frac{\rho_i}{\rho_j} - 1 = S_{i,voisinage} - 1 \quad (11)$$

En utilisant (6), on obtient :

$$\begin{aligned} S'_{i,voisinage} &= 2 * \frac{\sin(\theta_d - \theta_i)}{\cos(\theta_d - \theta_i)} * (\sin \alpha + \sin 2\alpha + \dots + \sin(voisinage * \alpha)) \\ S'_{i,voisinage} &= 2 * \text{tg}(\theta_d - \theta_i) \sum_{j=1}^{voisinage} \sin j \alpha \end{aligned} \quad (12)$$

La grandeur $\sum_{j=1}^{voisinage} \sin j \alpha$ de l'équation (12) ne dépend que du voisinage et de la résolution angulaire.

L'orientation θ_d de la droite support, après le calcul de $S'_{i,voisinage}$ donné par (11) est alors :

$$\theta_d = \theta_i + \text{arctg} \frac{S'_{i,voisinage}}{2 \sum_{j=1}^{voisinage} \sin j \alpha} \quad (13)$$

Le calcul des imprécisions sur θ_d est obtenu en utilisant le formalisme développé dans [Arras, 1998] où, après un développement de Taylor et des hypothèses réalistes sur l'indépendance entre les bruits sur les mesures (ρ , θ). On reprend l'idée de la propagation des erreurs dans un système à entrées et sorties connues pour obtenir alors :

$$\sigma_{\theta_d}^2 = \sum_{j=1}^n \left(\frac{\partial \theta_d}{\partial \rho_j} \right)^2 \sigma_{\rho_j}^2,$$

où n est le nombre d'impacts du segment ,

$$\frac{\partial \theta_d}{\partial \rho_j} = \frac{1}{1 + \left(\sum_{k=1}^n \text{sign}(k - \frac{n+1}{2}) \frac{\rho_c}{\rho_j} - 1 \right)^2} \cdot \text{sign}(\frac{n+1}{2} - j) \cdot \frac{\rho_c}{\rho_j^2} \quad \text{et ,}$$

ρ_c la distance au capteur de l'impact central du segment (le milieu de l'accumulation).

Comme l'imprécision en distance est la même pour tous les impacts, on a :

$$\sigma_{\theta_d}^2 = \sigma_{\rho}^2 \sum_{j=1}^n \left(\frac{\partial \theta_d}{\partial \rho_j} \right)^2 \quad (14)$$

Après le calcul de l'orientation et de l'imprécision associée, une procédure de fusion des segments proches qui sont colinéaires (ou presque) est effectuée en reprenant la procédure de *merging* (Algorithme 5) du paragraphe III.5.2.2.

Le calcul de la nouvelle orientation ainsi que l'imprécision associée se fait alors avec l'ensemble des impacts des deux segments fusionnés en utilisant à nouveau les formules (11), (13) et (14). Cependant, il est obligatoire d'enlever un impact afin d'obtenir un nombre impair d'impacts et pouvoir s'appuyer sur l'impact central. Par choix, nous enlevons systématiquement le premier impact du premier segment fusionné (dans l'ordre du balayage).

Calcul de ρ_d pour la droite support du segment

Nous avons donc calculé l'orientation de la droite support du segment à l'aide de (11). Cependant, cette droite passe par le point central de l'accumulation. Pour déterminer l'autre paramètre de la droite (ρ_d), nous proposons de minimiser l'écart en distance orthogonale à la droite de chacun des points de l'accumulation, connaissant l'orientation θ_d obtenue par (13). Cette détermination de ρ_d est inspiré de celle rencontrée dans le paragraphe III.5.1.2 (minimisation quadratique), où une fois que l'orientation de la droite est déterminée, on calcule ρ_d comme la moyenne des distances orthogonales de tous les impacts à la droite support (donc dans la direction donnée par θ_d). On a donc, pour un segment provenant d'une accumulation dont l'impact central est $t_i = (\rho_i, \theta_i)$:

$$\rho_d = \frac{1}{2 * \text{voisinage} + 1} \sum_{j=-\text{voisinage}}^{\text{voisinage}} \rho_{i-j} \cos(\theta_d - \theta_{i-j}) \quad (15)$$

Le calcul des imprécisions sur ρ_d , est également obtenu à partir de [Arras, 1998] :

$$\sigma_{\rho_d}^2 = \sum_{j=1}^n \left(\frac{\partial \rho_d}{\partial \rho_j} \right)^2 \sigma_{\rho_j}^2 = \sigma_{\rho}^2 \sum_{j=1}^n \left(\frac{\partial \rho_d}{\partial \rho_j} \right)^2 \quad (16)$$

avec n le nombre d'impacts du segment,

$$\frac{\partial \rho_d}{\partial \rho_j} = \frac{1}{n} \cos(\theta_j - \theta_d) + \frac{\partial \theta_d}{\partial \rho_j} (y_{moy} \cos \theta_d - x_{moy} \sin \theta_d)$$

$$\text{où } x_{moy} = \frac{1}{n} \sum_{k=1}^n x_k \text{ et } y_{moy} = \frac{1}{n} \sum_{k=1}^n y_k$$

L'ensemble des erreurs sur les paramètres de la droite support s'exprime alors par la matrice de covariance :

$$\text{cov}_{\text{droite support}} = \begin{pmatrix} \sigma_{\rho_d}^2 & \sigma_{\rho_d \theta_d} \\ \sigma_{\theta_d \rho_d} & \sigma_{\theta_d}^2 \end{pmatrix}$$

On peut également obtenir l'expression des termes croisés de la matrice de covariance de la même manière :

$$\sigma_{\theta_d \rho_d} = \sigma_{\rho_d \theta_d} = \sigma_{\rho}^2 \sum_{j=1}^n \frac{\partial \theta_d}{\partial \rho_j} \frac{\partial \rho_d}{\partial \rho_j} \quad (17)$$

Calcul des autres paramètres (extrémités, milieu, longueur)

Les calculs de tous les autres paramètres, ainsi que les imprécisions associées, peuvent être obtenus alors sans aucune difficulté en reprenant toutes les formules données dans le paragraphe III.5.2.3. On rappellera que le choix des paramètres extraits est avant tout lié aux besoins des algorithmes qui utilisent les segments comme des observations de l'environnement.

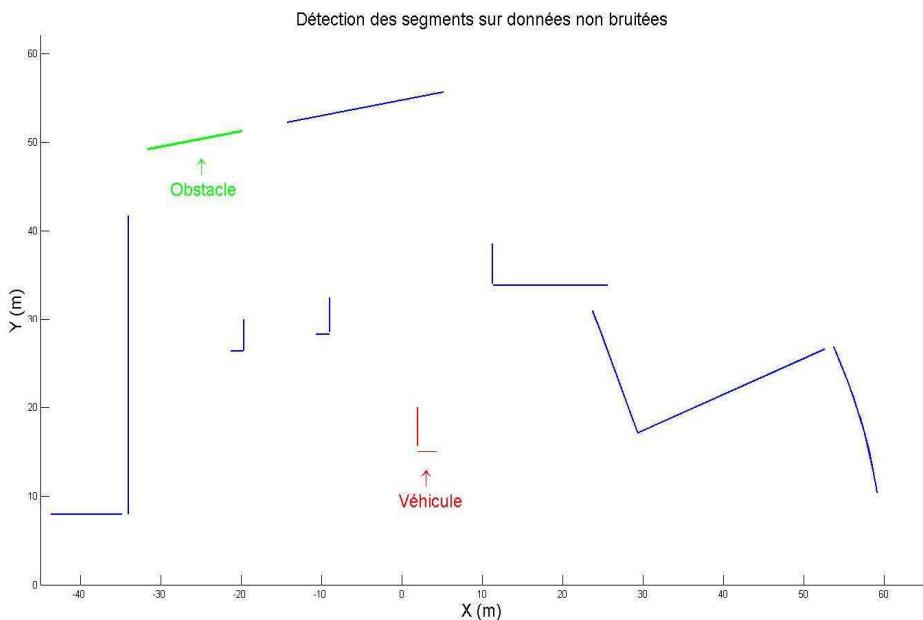


Figure 69 : Résultat de la détection pour les mesures non bruitées de la figure 64.

On peut voir, sur la figure 69, le résultat de la segmentation et de l'extraction des paramètres des segments présents dans le balayage de la figure 64. Ces résultats sont tout à fait corrects pour des mesures non bruitées. On peut remarquer que les segments détectés sont de taille légèrement plus petite que la taille réelle. Ceci est dû à la résolution angulaire du capteur. On remarque également que la légère courbe, à droite de la figure, est parfaitement approchée par une suite de segments.

III.6.3 Application de la méthode sur données bruitées

La méthode de segmentation proposée donne de bons résultats sur des données non bruitées. Pour valider cette approche, nous allons l'appliquer à des données synthétiques bruitées, avec un bruit sur la distance ρ de l'ordre de $\sigma_\rho = 0,03\text{m}$ et un bruit nul sur l'angle θ , correspondant aux imprécisions des données réelles (données constructeur).

Le principe général de l'algorithme de segmentation reste le même. Mais quelques adaptations sont nécessaires.

En présence d'un bruit gaussien sur la distance ρ (ayant un écart-type σ_ρ), le terme $S_{i,\text{voisinage}}$ calculé par (9) est une variable aléatoire gaussienne dont on peut déterminer l'écart-type. En première approximation (le calcul détaillé est donné en Annexe B), l'écart-type $\sigma_{S_{i,\text{voisinage}}}$ est :

$$\sigma_{S_{i,voisinage}} \approx \frac{\sigma_{\rho_i}}{\rho_i} \left| S_{voisinage \text{ théorique}} - 1 \right| \approx \frac{\sigma_{\rho_i}}{\rho_i} * 2 \sum_{j=1}^{voisinage} \cos j \alpha \quad (18)$$

Cette valeur de l'imprécision peut alors servir de seuil pour comparer l'écart entre $S_{i,voisinage}$ calculé pour l'impact t_i et l'invariant théorique $S_{voisinage \text{ théorique}}$. Comme $S_{i,voisinage}$ est une variable aléatoire gaussienne, on fixe ce seuil à $Seuil_{calculé} = 3 * \sigma_{S_{i,voisinage}}$ pour traiter environ 99% des valeurs favorables.

Pour illustrer la qualité du seuil choisi, la figure 70 et la figure 71 montrent des résultats de segmentation et de détection pour différentes valeurs de seuils. On peut voir sur ces résultats qu'en fonction du seuil (et surtout s'il est trop élevé), l'algorithme associe systématiquement aux accumulations un certain nombre d'impacts provenant des segments voisins. Ce phénomène apparaît d'autant plus que l'on augmente le seuil. Ceci a surtout pour conséquence de modifier l'orientation du segment détecté. Une diminution du seuil permet de pallier ce problème mais a pour conséquence d'obtenir des accumulation maximales plus petites et donc beaucoup de segments de taille plus petite. Une autre solution, que nous appellerons *rognage*, consiste à enlever quelques impacts aux extrémités des accumulations. Ceci aura bien entendu pour effet de diminuer la taille des accumulations mais aussi de diminuer l'influence de ces erreurs d'association d'impacts sur le calcul des orientations des droites. Nous avons défini que le nombre d'impacts retirés de part et d'autre de l'accumulation doit varier en fonction du nombre d'impacts total de l'accumulation (pour l'exemple, on enlève environ 20% de la totalité des impacts, soit 10% de chaque côté). Sur les résultats présentés, ceux obtenus avec le seuil calculé reste les meilleurs dans tous les cas. Afin d'obtenir les orientations des segments détectés non faussées par les mauvaises associations d'impacts, nous appliquons également un *rognage*, de l'ordre de 10% de la totalité des impacts formant chacune de accumulations.

Une autre adaptation de l'algorithme concerne la détection des pics sur les accumulations maximales. Lorsque l'on regarde les accumulations de la figure 70, on remarque, quel que soit le seuil choisi, deux phénomènes : des points manquants qui correspondent à des *outliers* filtrés par la segmentation, mais aussi des *outliers* non filtrés représentés par les impacts n'appartenant pas aux triangles apparents. Le choix qui consisterait à essayer de détecter les enveloppes maximales des triangles induirait d'intégrer ces *outliers* aux segments et donc de fausser la détermination des paramètres des segments. L'un des objectifs des méthodes de segmentation étant d'être robustes aux *outliers*, nous avons opté pour une recherche des triangles de plus grandes tailles, mais n'incluant pas les points considérés comme des *outliers*. Il suffit de se souvenir qu'un segment est représenté par un triangle de pente (-1) et (+1), c'est-à-dire dont la base est deux fois la hauteur. Nous obtenons alors, certes des segments de plus petites tailles mais sans *outliers*, garantissant ainsi la robustesse de la détection.

Les résultats de la figure 71 sont donnés sans la procédure de *merging* de manière à bien montrer les résultats de la segmentation avant l'extraction des paramètres. Pour la suite de la modélisation, le *merging* est appliqué dans tous les cas.

Une fois la détection de segments réalisée (segmentation et extraction des paramètres), nous modélisons les segments par des rectangles comme nous l'avons présenté dans le chapitre III.5.4. Des résultats de cette modélisation seront visualisés dans le chapitre suivant.

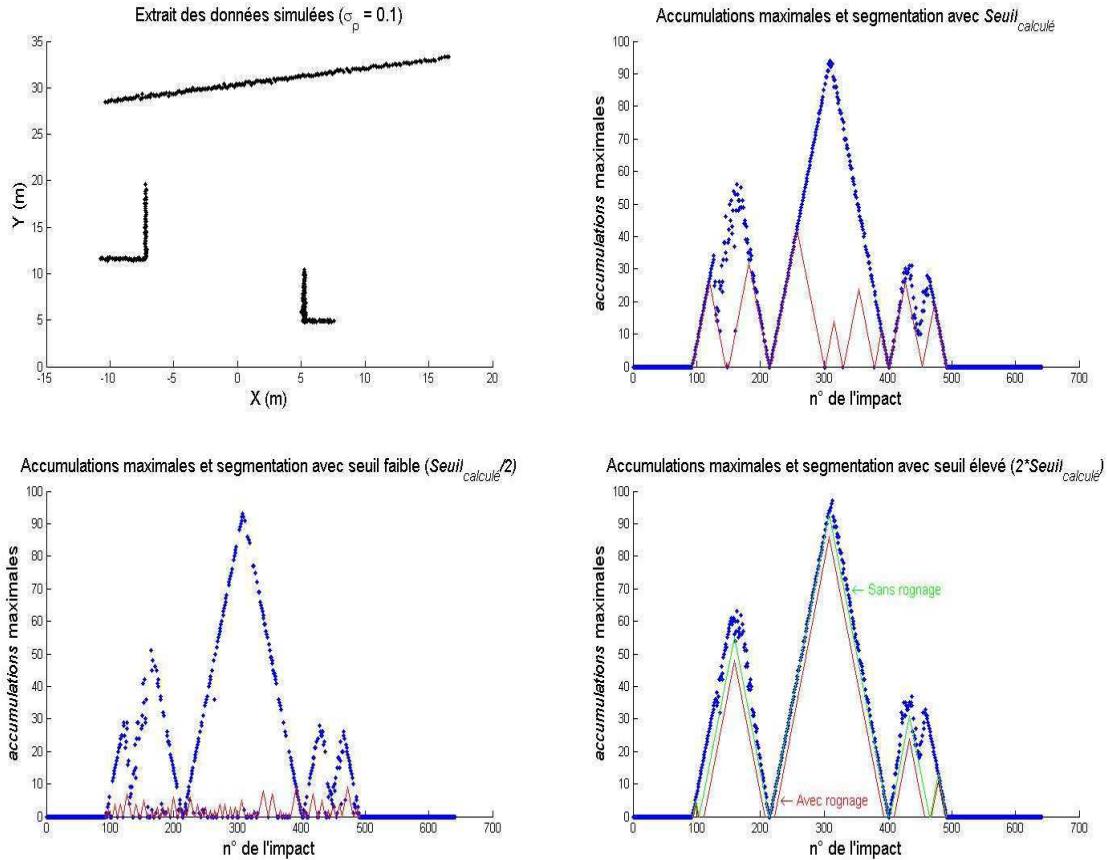


Figure 70 : Différentes accumulations maximales en fonction du seuil.

Nous présentons, sur la Figure 72, deux détails de deux acquisitions différentes d'une détection (segmentation, modélisation) provenant de données réelles (ces données sont issues des acquisitions qui nous ont été fournies par l'Ecole Nationale Supérieure des Mines de Paris et qui ont été présentées dans le chapitre II.5.2). Nous montrons également par cette figure la modélisation dans le cas où il n'y a qu'un seul segment et dans le cas où il y en a deux (avec détection de coin).

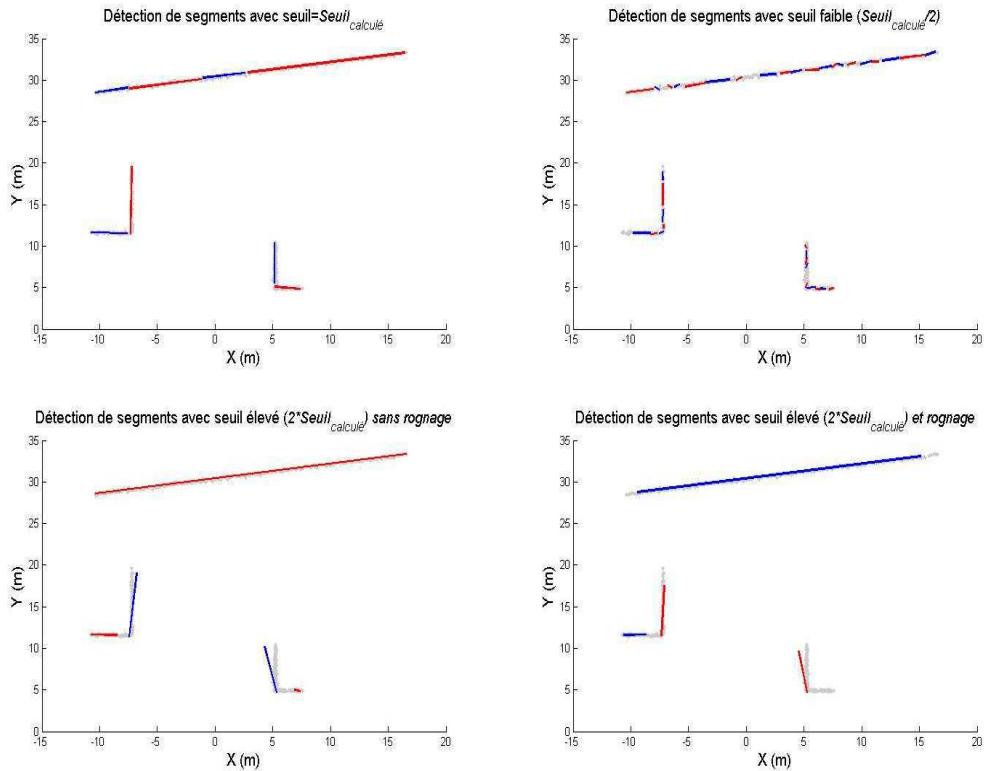


Figure 71 : Détections en fonction du seuil et du rognage.

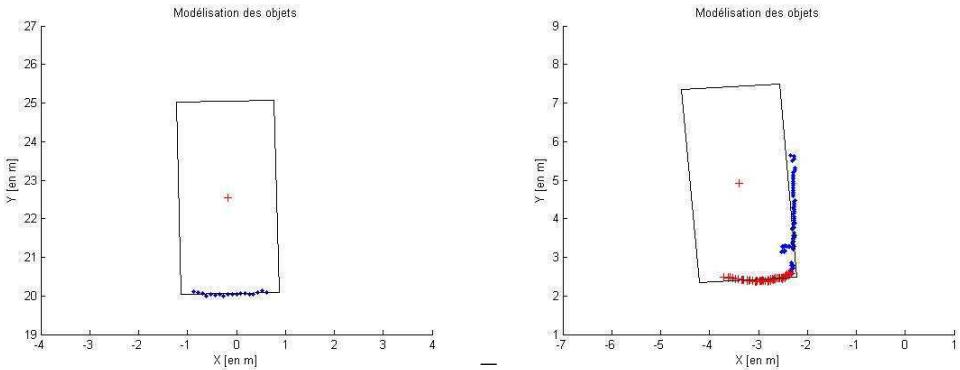


Figure 72 : Détails de deux détections sur données réelles (principe de modélisation par des rectangles)

III.7 Evaluation de l'algorithme de détection par invariant

Afin de pouvoir caractériser cet algorithme de détection, d'en donner ces performances et de le comparer avec d'autres méthodes classiques couramment utilisées (*Line-Tracking* et *Split-and-Merge*), nous avons développé un simulateur. L'utilisation de données synthétiques permet de pouvoir choisir, par le biais de paramètres du simulateur, les situations que l'on souhaite traiter et ainsi de pouvoir tester facilement les performances des algorithmes en fonction de certaines variables liées à ces situations.

L'exemple (figure 64) utilisé pour décrire l'algorithme de détection proposé provient de ce simulateur. Celui-ci permet de simuler le fonctionnement d'un capteur télémétrique laser placé dans un environnement polyédrique modulable. Nous allons présenter rapidement ce simulateur et ses différents paramètres variables.

Concernant la simulation du capteur, les paramètres variables du capteur simulé sont :

- la résolution angulaire α ;
- l'angle d'ouverture β avec un angle limite à droite (*ang_lim_droite*) et un angle limite à gauche (*ang_lim_gauche*) ;
- la portée maximale (*portée_max*) et la limite minimale d'observation (*portée_min*). Les paramètres β , *portée_max* et *portée_min* définissent le champ de vision du capteur.

L'environnement est décrit en plaçant des objets polyédriques dans la zone d'observation du capteur. Les paramètres de réglage du placement de ces objets sont :

- le nombre de véhicules (*Nb_veh*). On a la possibilité de placer également tout autre type d'objets, mais de forme polyédrique ;
- la taille, la position et l'orientation des objets ;
- deux limites en distances (*Veh_min* et *Veh_max*) afin de placer les véhicules entre ces deux limites et pouvoir évaluer les performances en fonction de la distance entre les véhicules et le capteur ;
- deux limites (*X_min* et *X_max*) pour limiter la présence des véhicules dans une zone pouvant être comparée à une limitation de zone d'observation (par exemple, les voies d'une autoroute à l'avant du véhicule portant le capteur) ;
- un taux de visibilité garanti $T_{visibilité}$. Lorsque l'on place un véhicule dans l'environnement, il est important de savoir la quantité de la surface de ce véhicule qui est observable par le capteur par rapport à sa surface visible, s'il était seul dans la scène et complètement dans le champ d'observation. On définit alors $T_{visibilité} = \frac{\text{Surface observable}}{\text{Surface visible (si seul)}}$, qui garantira que l'objet

placé a une proportion de surface observable au moins égale à ce taux. $T_{visibilité} = 1$ garantit donc la visibilité totale de tous les objets de la scène (pas d'occultation) et $T_{visibilité} = 0$ entraîne que certains des objets placés peuvent être totalement invisibles, *i.e.* occultés ou hors champ. En effet, la perte de visibilité peut provenir d'une occultation partielle par un autre objet mais aussi être provoquée par la sortie éventuelle d'une partie de l'objet du champ d'observation. Ce taux sera utile pour évaluer les performances de l'algorithme face aux occultations et aux changements de formes évoquées dans le paragraphe III.5.4;

- la possibilité d'ajouter des mesures aberrantes, pour simuler la présence d'*outliers* avec une probabilité $P_{outlier}$.

III.7.1 Présentation du protocole d'expérimentation

Pour évaluer les performances des algorithmes de détection de véhicules, nous avons simulé des mesures en plaçant des objets de forme rectangulaire, dont les dimensions moyennes sont équivalentes à celles d'un véhicule, dans le champ de vision du capteur.

Pour chacune des acquisitions, Nb_{veh} véhicules sont placés aléatoirement en position et en orientation (la taille est constante, fixée avant la simulation). Il s'agit bien de simulation statique, puisqu'aucune considération dynamique des objets n'est prise en compte et de fait, les acquisitions sont indépendantes les unes des autres.

Les principaux paramètres du capteur simulé, illustrés sur la figure 73, sont :

- $\beta=160^\circ$: l'angle d'ouverture est compris entre 10° et 170° , comparable à celui d'un IBEO;
- $\alpha= \{0,25^\circ ; 0,5^\circ ; 1^\circ\}$. La résolution par défaut est $0,25^\circ$. Nous la préciserons lors des résultats si elle est différente ;
- portée_max =80m et portée_min =2m ;
- une limitation du champ d'observation donnée par $X_{min} = -15m$ et $X_{max} = 15m$;

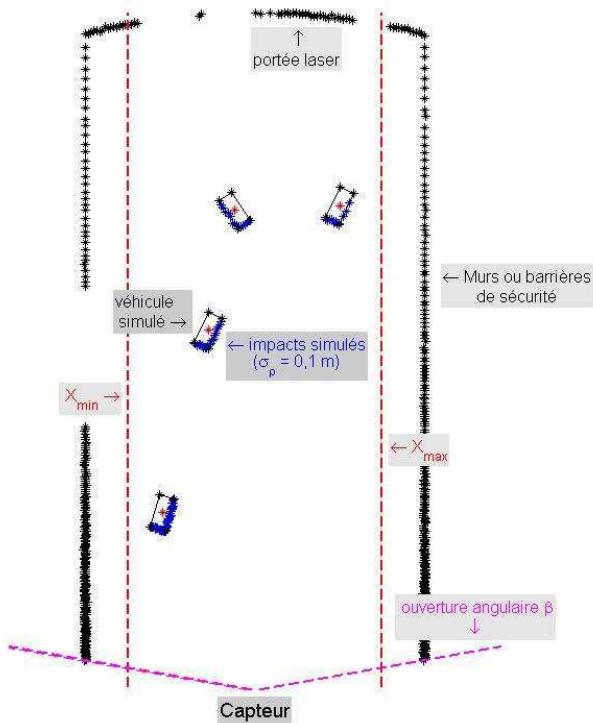


Figure 73 : Exemple d'une acquisition simulée avec visualisation de certains paramètres.

Pour chacune des positions simulées, nous ajoutons une erreur sur chacune des mesures. Les écart-type des erreurs sur la distance σ_ρ seront variables, compris entre $\sigma_\rho = 0,01m$ et $\sigma_\rho = 0,13m$ (au-delà, les mesures ne semblent plus réalistes pour des télémètres) lorsqu'il s'agira d'établir les performances en fonction des bruits de mesure. Pour les autres évaluations, nous choisirons un σ_ρ comparable aux imprécisions des télémètres réels, soit σ_ρ de l'ordre de 0,03m. Les imprécisions en angle σ_θ sont prises nulles, conformément aux données des constructeurs (mais on peut toutefois envisager de prendre σ_θ faible de l'ordre de 10^3 rad).

Pour évaluer l'influence du bruit des mesures sur la détection, nous effectuons une moyenne statistique de type Monte Carlo de $Nb_{itération}$ tirage de bruit pour une même simulation des véhicules. Si l'on appelle Nb_{simu} le nombre de simulations différentes, nous aurons le nombre total

d'acquisitions traitées qui sera $Nb_{acq} = Nb_{simu} * Nb_{itération}$. Typiquement $Nb_{simu} = 1000$ et $Nb_{itération} = 100$, donc $Nb_{acq} = 10^5$ acquisitions.

Nous allons tout d'abord comparer les performances des trois algorithmes de détection implémentés : deux algorithmes classiques *Line-Tracking* (nommé *Inc*) et *Split-and-Merge* (nommé *S&M*) ainsi que l'algorithme proposé basé sur les invariants (nommé *Inv*). Ensuite, nous caractériserons plus en détail les performances de l'algorithme *Inv* en fonction de différents paramètres.

Les performances des algorithmes sont données selon l'efficacité du détecteur, la précision des objets détectés et la vitesse de traitements qui sont établies durant toute la durée de la simulation.

Pour l'efficacité, deux termes sont déterminés :

- la probabilité de détection $P_d = \frac{\sum_{Nb_{acq}} \text{Objets correctement détectés}}{\sum_{Nb_{acq}} \text{Objets présents}}$
- la probabilité de fausse alarme $P_{fa} = \frac{\sum_{Nb_{acq}} \text{Fausses alarmes} (= \text{Objets détectés mais pas présents})}{\sum_{Nb_{acq}} \text{Objets présents}}$

On considérera qu'un objet est bien détecté si sa position obtenue après la phase de détection correspond bien à l'objet initial. Nous avons pour cela déterminé une distance acceptable correspondant à la diagonale du rectangle modélisant l'objet. Si un objet est détecté mais que son centre est situé à une distance supérieure à cette distance, alors il sera considéré comme une fausse alarme. Dans le cas où il y a plusieurs détections pour le même objet, la détection la plus proche en distance et en angle sera considérée comme l'objet détecté. Toutes les autres détections seront considérées comme des fausses alarmes. La probabilité de fausses alarmes est souvent présentée par la densité volumique ou surfacique de fausses alarmes, qui est donnée par $\frac{P_{fa}}{Surf_{observation}}$, où

$Surf_{observation}$ est la surface d'observation du capteur qui dépend, pour le simulateur, des paramètres β , Veh_{min} , Veh_{max} , X_{min} et X_{max} . Cette surface sera donc calculée et fournie à chaque nouveau choix d'environnement de manière à pouvoir calculer la densité de fausses alarmes de l'algorithme étudié.

Pour la précision, en ne traitant bien sûr uniquement que les bonnes détections, nous calculons les erreurs moyennes en distance $\overline{\Delta_\rho}$ entre les positions réelles (x_{veh} , y_{veh}) des centres des véhicules et les centres (x_{rect} , y_{rect}) des modèles rectangles détectés, ainsi que les erreurs moyennes en orientation $\overline{\Delta_\theta}$ entre les orientations réelles θ_{veh} des véhicules et les orientations θ_{rect} des modèles rectangles détectés :

- $\overline{\Delta_\rho} = \frac{1}{Nb_{acq}} \sum_{Nb_{acq}} \sqrt{(x_{veh} - x_{rect})^2 + (y_{veh} - y_{rect})^2}$
- $\overline{\Delta_\theta} = \frac{1}{Nb_{acq}} \sum_{Nb_{acq}} (\theta_{veh} - \theta_{rect})$

Les variances de ces deux erreurs moyennes pourront être également calculées, et nous comparerons avec les bornes des imprécisions proposées dans le paragraphe III.5.4.2:

- $\sigma_{\Delta_\rho}^2 = \frac{1}{Nb_{acq}-1} \sum_{Nb_{acq}} \left[(\sqrt{(x_{veh} - x_{rect})^2 + (y_{veh} - y_{rect})^2}) - \overline{\Delta_\rho} \right]^2$
- $\sigma_{\Delta_\theta}^2 = \frac{1}{Nb_{acq}-1} \sum_{Nb_{acq}} \left[(\theta_{veh} - \theta_{rect}) - \overline{\Delta_\theta} \right]^2$

Pour l'évaluation de la vitesse, nous exprimons la fréquence de détection de chacun des algorithmes. Il ne s'agit pas d'obtenir une mesure absolue de la durée des traitements pour chaque algorithme, mais bien une grandeur relative afin de pouvoir qualifier les algorithmes entre eux, à la condition que toutes les détections soient obtenues à partir du même jeu d'acquisitions et sur la même machine. Pour ces évaluations, toutes les détections sont faites en Matlab[®] sur le même ordinateur (processeur Intel Pentium M 1,6 GHz). La fréquence de détection en Hz est donnée par :

$$Fréq_{détect} = \frac{\sum_{Nb_{acq}} \text{Objets détectés}}{\text{Durée totale de détection}}.$$

III.7.2 Evaluation et comparaison des méthodes de détection

III.7.2.1 Comparaison avec les autres algorithmes de détection

Nous allons dans un premier temps faire la comparaison des performances de la méthode de détection *Inv* avec les deux autres algorithmes que nous avons implémentés (*Inc* et *S&M*), en fonction du bruit sur les mesures et observer les comportements en fonction du nombre de véhicules présents dans la scène.

Cas d'un seul véhicule présent dans la zone d'observation

Pour cette première simulation, nous n'avons placé qu'un seul véhicule dans la zone d'observation avec les conditions suivantes :

- $Veh_{min} = portée_{min} \approx 2m$ selon la taille de l'objet ;
- $Veh_{max} = portée_{max} = 80m$;
- $\alpha = 0,25^\circ$;
- $T_{visibilité} = 25\%$, soit au moins un quart de la surface de l'objet observable (comme il n'y a qu'un seul objet présent à chaque acquisition, ce sont les sorties éventuelles du champ de vision qui sont ainsi traitées).
- on montre sur la figure 74 les évolutions de différents paramètres de performance pour les trois algorithmes implémentés en fonction de l'écart-type de l'erreur en distance σ_ρ . Ces performances sont bien sûr obtenues en effectuant la détection sur les mêmes acquisitions simulées (1000 acquisitions) et en effectuant une moyenne statistique sur 50 itérations par acquisition.

Cette première comparaison nous permet d'affirmer que la méthode de détection *Inv* proposée a des performances très comparables avec la méthode *Split and Merge*, qui est sûrement l'une des plus couramment utilisée lorsque l'on ne veut pas mettre en œuvre des méthodes plus lourdes telles que celles basées sur la transformée de Hough ou *RANSAC*. Pour les niveaux de bruits étudiés, notre méthode donne des résultats similaires en ce qui concerne la probabilité de détection et la

probabilité de fausses alarmes, que nous avons choisi d'exprimer par la densité spatiale de fausses alarmes puisque c'est sous cette forme que les fausses alarmes sont intégrées dans les méthodes PDA. La méthode par invariants semble surtout plus précise en position et en orientation. Nous rappelons toutefois qu'il faut surtout observer les performances pour $\sigma_p=0,03\text{m}$, puisque c'est le niveau de bruit des erreurs pour les données réelles.

A la vue de ces premiers résultats, nous éliminerons de la suite de la comparaison la méthode Incrémentation qui n'a, non seulement pas des performances comparables, mais qui a aussi le défaut d'être de l'ordre de trois fois moins rapide dans les traitements que notre méthode.

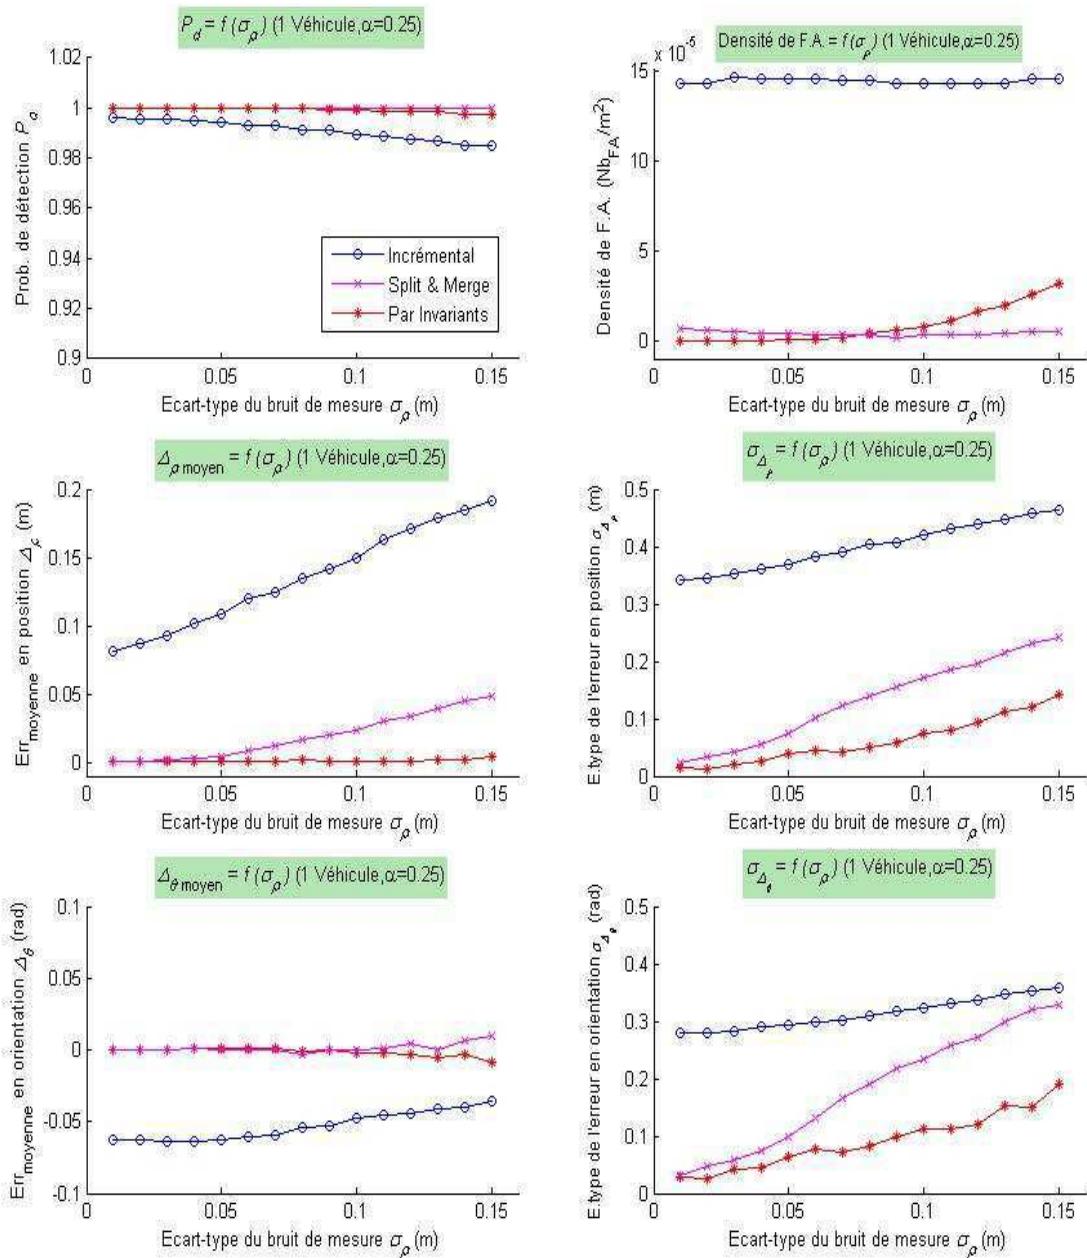


Figure 74 : Comparaison des performances des algorithmes Inv, Inc et S&M en fonction du bruit σ_p .

Cas de plusieurs véhicules présents dans la zone d'observation

Nous allons maintenant montrer comment se comporte les deux algorithmes *Inv* et *S&M* lorsqu'il y a plusieurs objets dans la scène observée. Nous donnons les performances des deux algorithmes de détection pour un nombre de véhicules allant de un à quatre (figure 75). Les conditions de simulation sont équivalentes de celles du paragraphe précédent.

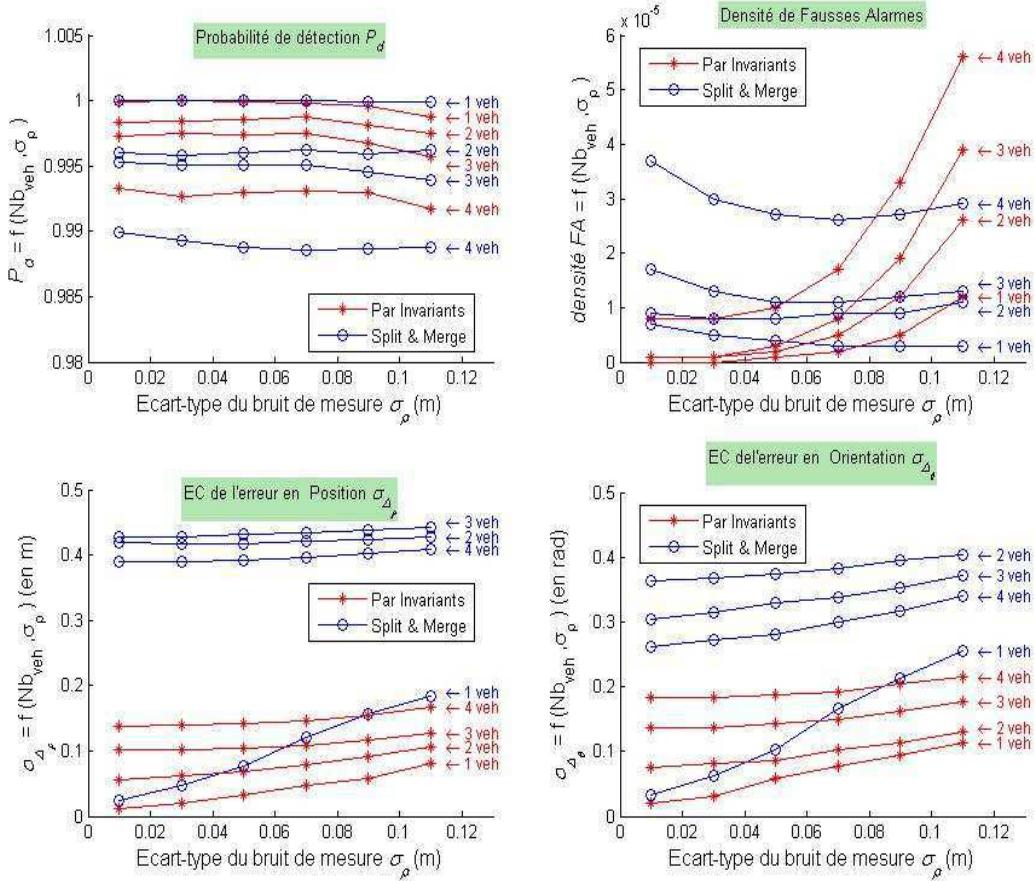


Figure 75 : Comparaison des performances des algorithmes *Inv* et *S&M* en fonction du nombre de véhicules et du bruit σ_p .

Ces résultats confirment les précédents, à savoir que notre méthode est dans tous les cas meilleure en précision et en probabilité de détection. On peut toutefois noter que lorsque le niveau de bruit devient élevé ($\sigma_p > 0,07\text{m}$), la méthode *S&M* donne de meilleures résultats en terme de probabilité de fausses alarmes et que l'écart devient d'autant plus important que le niveau de bruit et le nombre de véhicules augmentent. Malgré tout, cette valeur est acceptable pour l'algorithme *Inv*, surtout pour un σ_p proche de celui des données réelles (0,03m).

Comme nous l'avons déjà dit, il semble logique que les performances en détection soient avant tout liées aux nombres d'impacts représentant une surface de l'objet mesuré. Dans l'objectif de renforcer cette idée, nous donnons sur les figures (figure 76, figure 77, figure 78, figure 79), les performances des algorithmes *Inv* et *S&M*, toujours en fonction du nombre de véhicules (de 1 à 4), du bruit de mesures mais surtout en fonction de la résolution du capteur. A part la résolution du capteur qui va évoluer, $\alpha = \{0,25^\circ; 0,5^\circ; 1^\circ\}$, les conditions de simulations restent identiques aux précédentes.

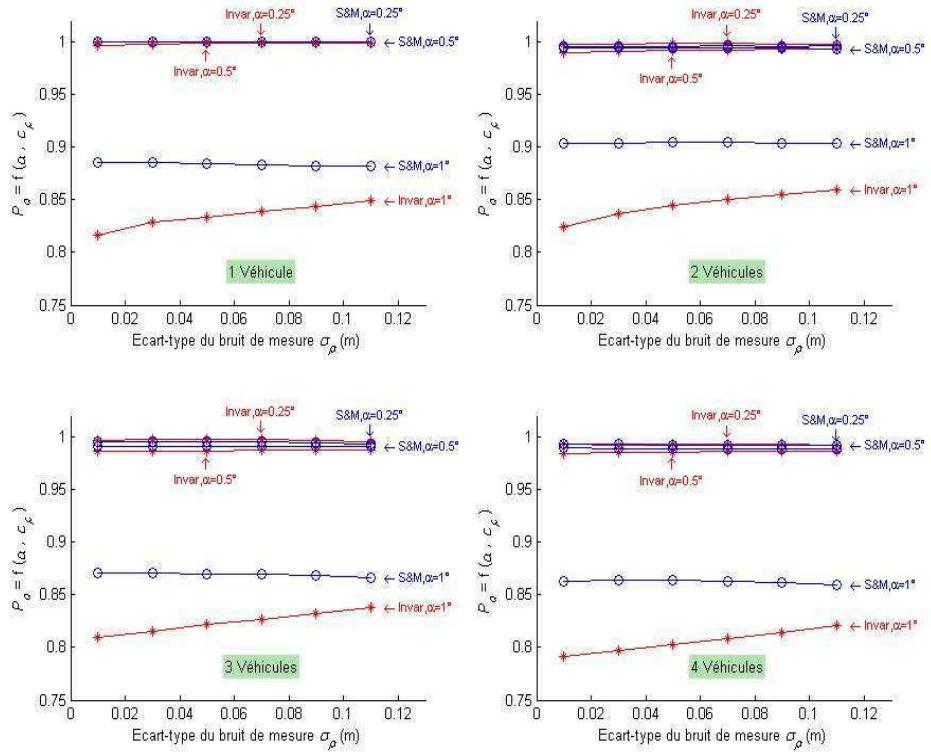


Figure 76 : Comparaison de la probabilité de détection des algorithmes Inv et S&M en fonction du nombre de véhicules, de la résolution du capteur et du bruit σ_p .

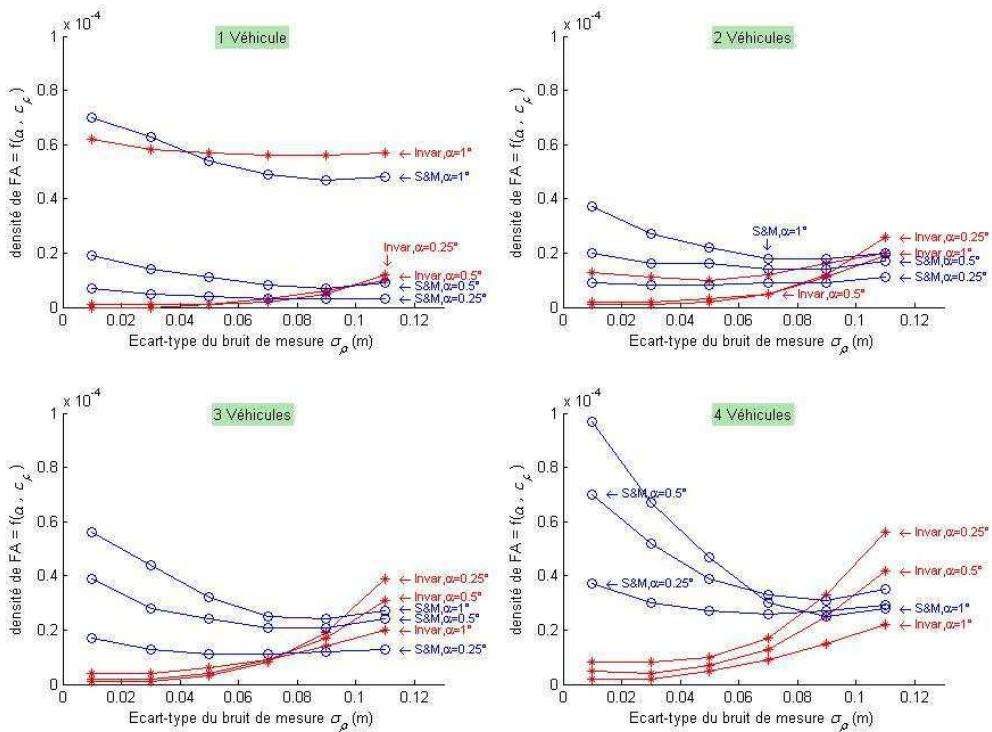


Figure 77 : Comparaison de densité de fausses alarmes des algorithmes Inv et S&M en fonction du nombre de véhicules, de la résolution du capteur et du bruit σ_p .

Pour la probabilité de détection, l'algorithme *Inv* proposée donne de sensiblement moins bon résultats lorsque la résolution augmente, mais on note que la dégradation est commune pour les deux méthodes lorsque $\alpha=1^\circ$, confirmant bien l'importance du nombre d'impacts par objet sur la qualité de détection.

Pour les fausses alarmes, les résultats sont similaires et restent très acceptables pour les deux méthodes. On peut toutefois noter une tendance difficile à expliquer : la densité de fausses alarmes a globalement tendance à diminuer pour *S&M* lorsque le bruit augmente, alors qu'elle a tendance à augmenter pour *Inv*, et ce quels que soient le nombre de véhicules et la résolution. Ce comportement s'explique vraisemblablement en raison des seuils utilisés dans les deux méthodes et en particulier celui de *S&M*, fortement lié à σ_p , qui permet d'assimiler plus d'impacts.

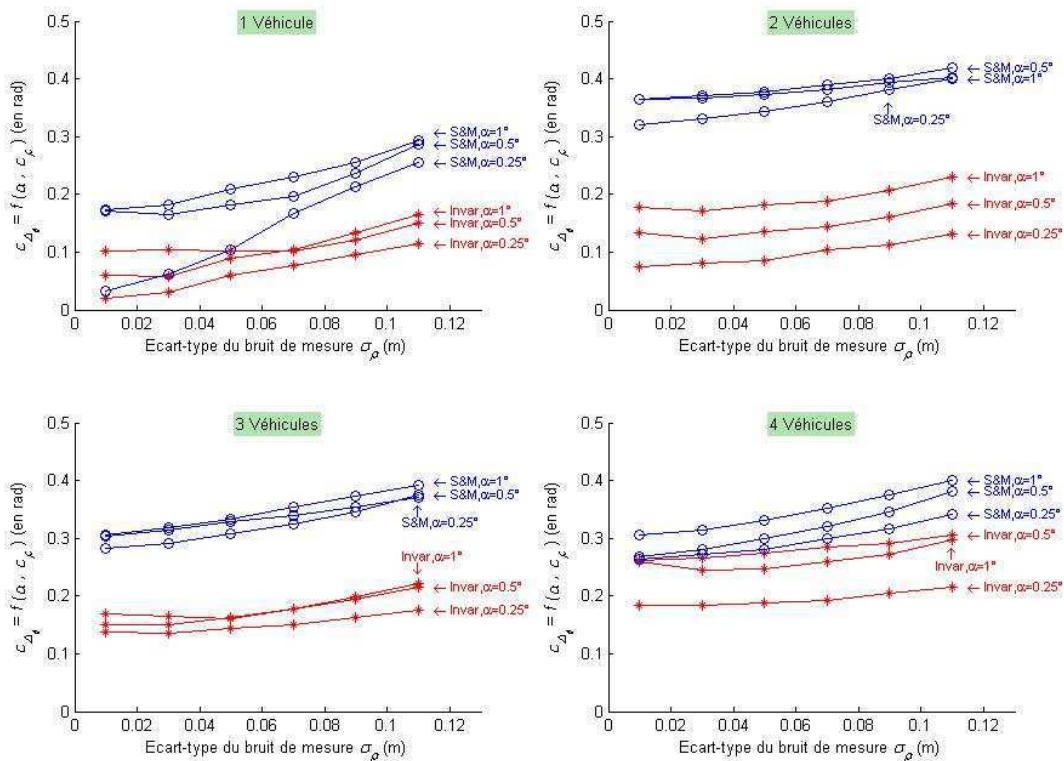


Figure 78 : Comparaison de l'écart-type de l'erreur de position des algorithmes *Inv* et *S&M* en fonction du nombre de véhicules, de la résolution du capteur et du bruit σ_p .

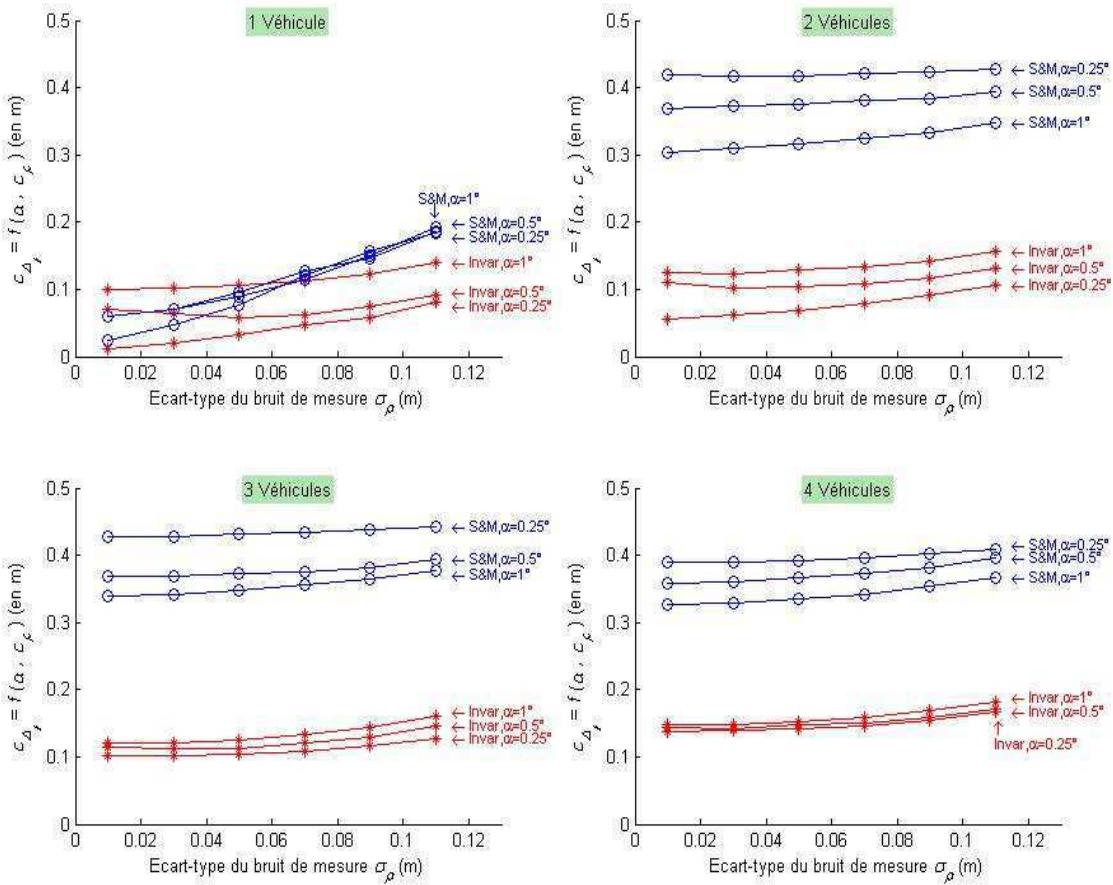


Figure 79 : Comparaison de l'écart-type de l'erreur d'orientation des algorithmes Inv et S&M en fonction du nombre de véhicules, de la résolution du capteur et du bruit σ_ρ .

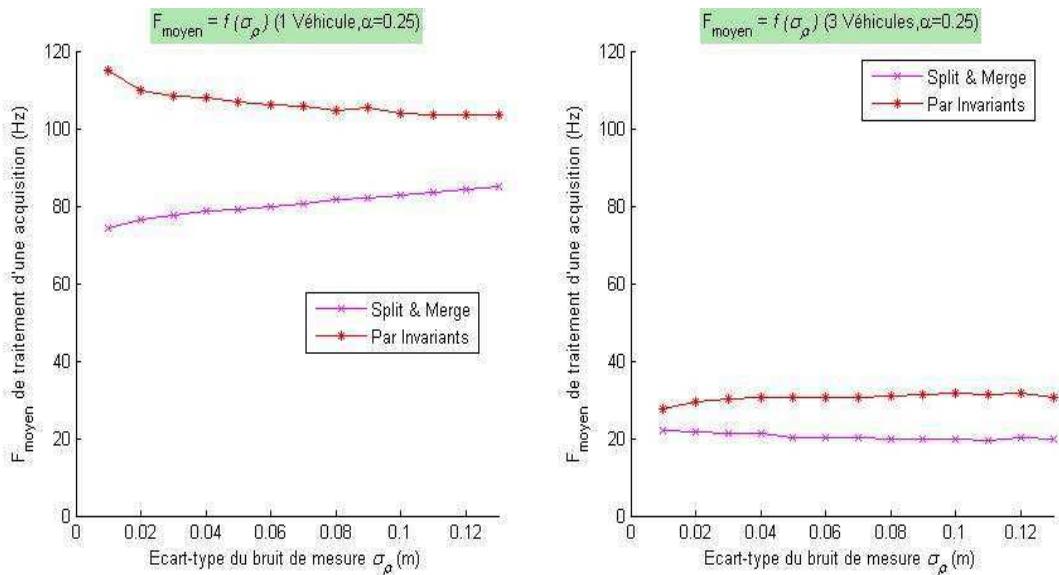


Figure 80 : Comparaison la vitesse relative ($Freq_{détection}$) des algorithmes Inv et S&M pour 1 et 3 véhicules en fonction du bruit de mesure σ_ρ .

Pour la précision, *Inv* est encore une fois meilleure dans tous les cas, mais on voit clairement que les erreurs en positions et en orientations augmentent toujours lorsque la résolution angulaire augmente.

Pour terminer cette comparaison, nous représentons sur la figure 80 l'évolution de la fréquence moyenne de détection. Il s'agit d'une représentation de la durée moyenne de traitement d'une acquisition. Les codes n'étant pas optimisés et les algorithmes étant, de plus, codés en Matlab[®], ces durées n'ont pas de valeur absolue mais permettent seulement de relativiser la vitesse d'un algorithme par rapport à l'autre. On voit clairement que la méthode proposée est plus rapide que *S&M*. Cependant, on peut noter, lorsqu'il y a un seul objet que la vitesse diminue pour *Inv* et augmente pour *S&M* lorsque le bruit augmente. Une des explications peut encore une fois se trouver dans les seuils. En effet le seuil de division de *Inv* n'étant pas directement lié à σ_p , il y a plus de petits segments traités lorsque le bruit augmente. On peut remarquer que la diminution de la vitesse est pratiquement proportionnelle au nombre de véhicules à traiter. La fréquence n'est pas exactement divisée par trois (pour trois véhicules au lieu d'un) surtout en raison des interactions entre les véhicules (les occultations) qui ne garantissent pas une réelle indépendance dans le traitement de chaque objet, surtout que pour l'exemple donné, on a pris un taux de visibilité $T_{visibilité} = 25\%$.

III.7.2.2 Performances de l'algorithme *Inv* en fonction du contexte capteur-objet

Nous allons maintenant caractériser l'algorithme de détection proposé en fonction des deux paramètres contextuels capteur-objet, *i.e.* la taille des véhicules et la distance capteur-objet, utilisé dans le chapitre II. Les résultats obtenus nous permettront de montrer l'évolution des performances de l'algorithme, mais nous délivreront également des informations primordiales sur les paramètres intrinsèques des réseaux bayésiens que nous utilisons dans le chapitre IV afin de faire évoluer la probabilité de détection P_d en fonction du contexte de la scène observée.

En fonction de la taille des véhicules

Pour voir l'influence de la taille sur les performances en terme d'efficacité (P_d et *Densité de fausses alarmes*), nous avons choisi 4 types de véhicules pouvant se trouver dans la scène. Les tailles respectives de ces véhicules sont bien sûr différentes mais correspondent à des tailles moyennes de différents types de véhicules que l'on peut rencontrer couramment en situation autoroutière. Ces types de véhicules et leurs tailles sont :

- les voitures compactes, que nous nommons « petites voitures » avec une longueur de 3m et une largeur de 1,5m ;
- les voitures berlines, nommées « voitures » de longueur 4m et de largeur 1,8m.
- les monospaces ou les véhicules utilitaires, nommés « van » de longueur 5,5m et de largeur 2,2m ;
- les camions, dont les dimensions sont 8m pour la longueur et 2,5m pour la largeur.

Pour bien voir l'influence de ce paramètre sur l'efficacité du détecteur, nous avons choisi tout d'abord un taux de visibilité $T_{visibilité} = 100\%$, garantissant aucune occultation, ni sortie du champ d'observation. On montre aussi les résultats pour $T_{visibilité} = 25\%$. Pour encore montrer l'importance du nombre d'impacts par objet observé, nous montrons aussi l'évolution pour différentes valeurs de la résolution α .

Les conditions de la simulation sont les suivantes :

- 4 véhicules, tous de même type, dans la scène ;
- $Veh_{min} = portée_{min} \approx 2m$ selon la taille de l'objet ;
- $Veh_{max} = portée_{max} = 80m$;
- α variable.
- 400 acquisitions différentes (avec une moyenne statistique sur 40 tirages de bruit).

Les résultats sont présentés sur la figure 81 et la figure 82. Dans tous les cas, l'augmentation de la taille des véhicules permet d'obtenir une meilleure efficacité de l'algorithme proposé et comme attendu, à taille de véhicule égale, plus le nombre d'impacts diminue par véhicule, plus les performances diminuent également. On peut toutefois remarquer que les variations des performances ne sont pas flagrantes pour les résolutions $\alpha = 0,25^\circ$ et $\alpha = 0,5^\circ$, même si on note une influence de la taille des objets détectés sur P_d et P_{fa} . On peut également voir que les performances se dégradent lorsque le taux de visibilité garantie diminue (on rappelle que $T_{visibilité} = 25\%$ signifie que tous les objets présents ont au moins 25% de leur surface visible qui est observable par le capteur). Cette évolution semble logique puisqu'il y a, dans certaines acquisitions, des surfaces plus petites à détecter.

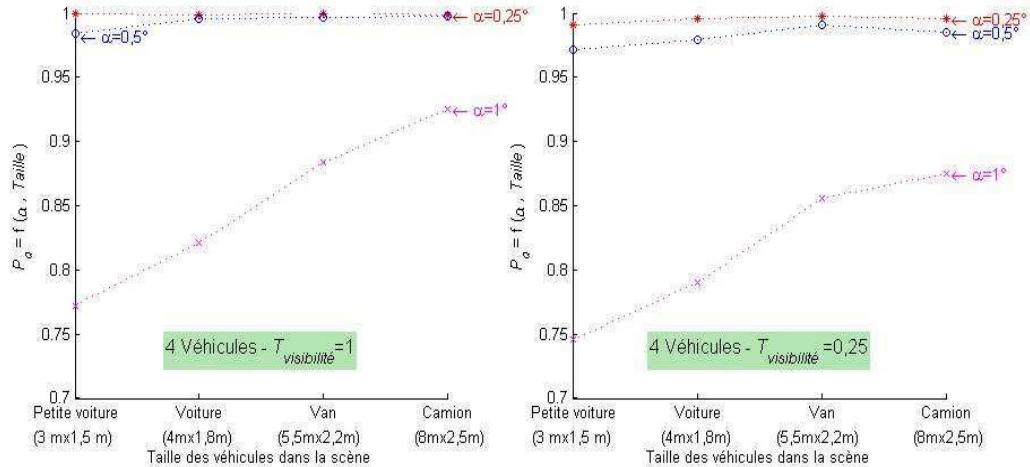


Figure 81 : Evolution de P_d en fonction de la taille des véhicules.

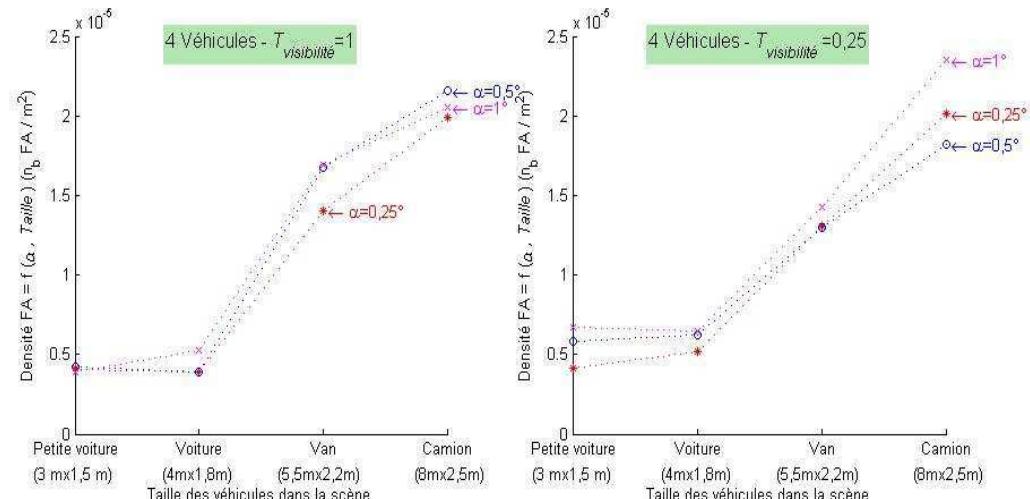


Figure 82 : Evolution de la Densité de fausses Alarme en fonction de la taille des véhicules.

En fonction de la distance moyenne des véhicules

En ce qui concerne l'évolution de l'efficacité de l'algorithme proposé en fonction de la distance capteur-objet, nous avons choisi de partitionner la zone d'observation en quatre zones, plaçant tour à tour des véhicules (de type le plus courant, à savoir « voiture ») uniquement dans chacune de ces zones. Les zones choisies sont les suivantes :

- de 0 à 20m du capteur (en fait, cette zone est légèrement plus petite car la plus petite distance du capteur à l'objet est Veh_{min} , puisque en deçà, il n'est pas observé) ;
- de 20 à 40m ;
- de 40 à 60m ;
- de 60 à 80m.

Les conditions de la simulation sont alors les suivantes :

- 4 « voitures » dans la scène ;
- Veh_{min} et Veh_{max} varient selon la zone observée ;
- α variable.
- 250 acquisitions différentes (avec une moyenne statistique sur 40 tirages de bruit).

La réduction du nombre d'acquisitions pour le calcul des performances a été faite par souci de temps de calcul, mais elle ne modifie pas la qualité des résultats puisque la taille de zone diminue.

On notera que pour le calcul de la densité de fausses alarmes, la surface d'observation $Surf_{observation}$ sera différente pour chacune de ces zones.

La discréétisation de l'espace d'observation ne permet pas de voir une évolution continue des performances, même si ça semble le cas sur les résultats proposés sur la figure 83 et la figure 84.

Sur ces figures, nous voyons que la distance influe sur l'efficacité de la détection des véhicules. Celles-ci restent très similaires dans les deux zones les plus proches (quelle que soit la résolution), mais les variations sont plus marquées dans les deux zones les plus éloignées, avec un saut important lorsque l'on détecte avec la résolution maximale dans la zone extrême. On voit aussi que, comme pour la taille, la diminution de $T_{visibilité}$ dégrade encore les performances.

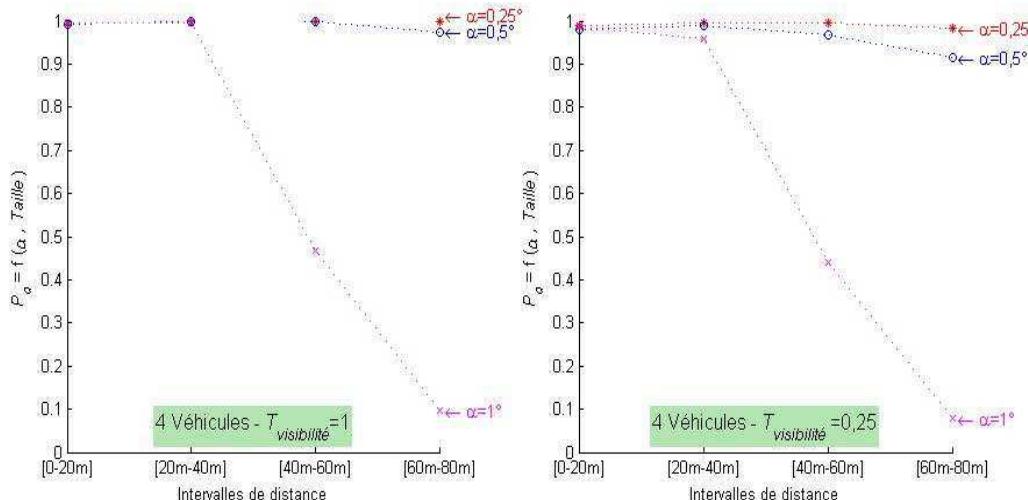


Figure 83 : Evolution de la Probabilité de détection en fonction de la distance.

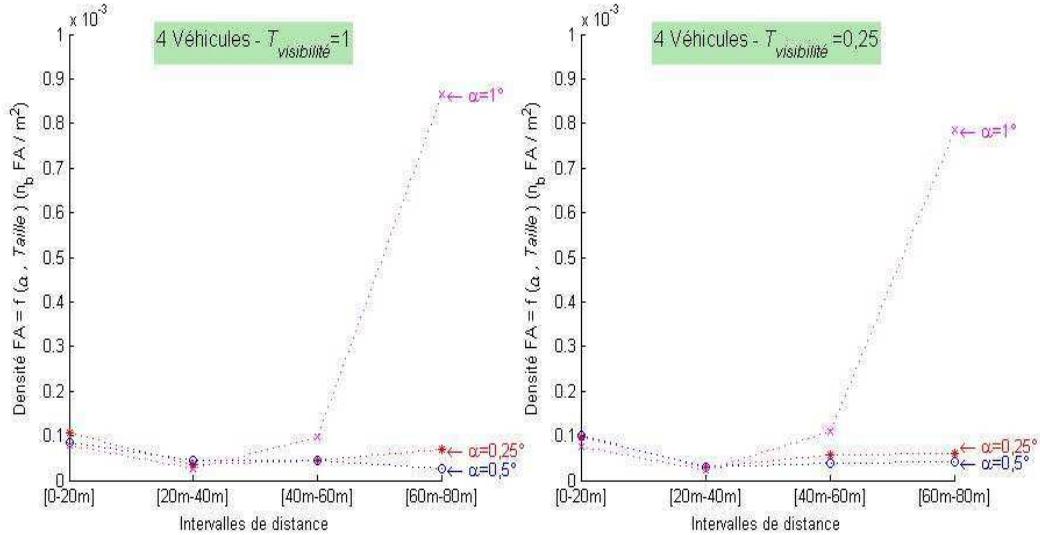


Figure 84 : Evolution de la Densité de fausses Alarme en fonction de distance.

Par ces résultats, nous avons formalisé la réelle influence des deux paramètres contextuels, utilisé dans le chapitre II, sur l'efficacité de la détection. De plus nous avons des résultats qui pourront être utilisé dans la définition des réseaux bayésiens du chapitre suivant. On peut noter toutefois que, même si pris un à un, ces paramètres ne semblent pas apporter de modifications significatives, la combinaison de leur influence altérera forcément l'efficacité de la détection. Nous avons encore une fois mis en évidence que l'un des facteurs clés est le nombre d'impacts par objet détecté, qui évolue fortement avec la résolution du capteur

III.7.2.3 Performances de l'algorithme *Inv* en fonction du contexte objet/objet

Voyons maintenant les modifications des performances lorsque l'on s'intéresse aux relations entre les objets, à savoir surtout les occultations entre eux. Nous allons donc proposer de faire varier le taux de visibilité garantie $T_{visibilité}$ et de voir comment évoluent les performances. Cette approche par $T_{visibilité}$ ne donnera pas d'informations directes sur le lien entre le taux d'occultation et les performances. En effet, si l'on prend par exemple $T_{visibilité}=50\%$, il se peut que tous les objets présents aient une surface visible divisée par 2 (en considérant les occultations et les sorties de zone) mais aussi que tous les objets présents soient parfaitement visibles. On voit donc que $T_{visibilité}$ n'est pas le taux d'occultation de la scène. Cependant, nous aurons une tendance pour l'évolution des performances en efficacité et en précision.

Nous n'avons pas testé les performances pour $T_{visibilité}=0\%$, puisque dans ce cas, il est possible qu'au moins un véhicule disparaisse complètement. Et que nous voulons garantir, pour ces simulations, à chaque fois le nombre de véhicules sélectionné.

Les conditions de la simulation sont les suivantes :

- 4 « voitures » dans la scène ;
- $Veh_{min} = \text{portée_min} \approx 2\text{m}$;
- $Veh_{max} = \text{portée_max} = 80\text{m}$;
- α variable.
- 400 acquisitions différentes (avec une moyenne statistique sur 40 tirages de bruit).

Les performances de l'algorithme proposé en relation avec les occultations apparaissent sur la Figure 85. Nous pouvons observer que les performances se détériorent pour un taux de visibilité garantie $T_{visibilité}$ qui diminue, c'est-à-dire pour une quantité d'occultation admissible qui augmente, et ce quelle que soit la résolution du capteur.

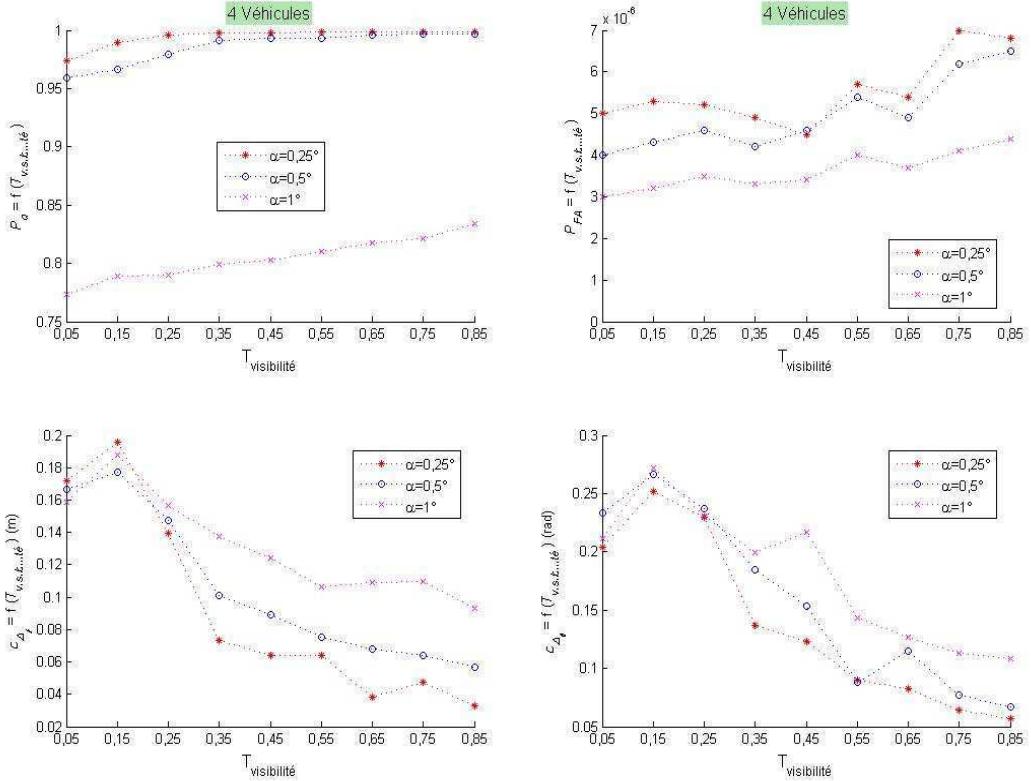


Figure 85 : Evolution des performances en fonction de $T_{visibilité}$ et de la résolution α .

Par ces résultats, nous montrons bien que les relations entre les objets (contexte objet/objet) vont, au même titre que le contexte capteur/objet, influer sur l'efficacité de la détection de l'algorithme proposé, et en particulier sur la probabilité de détection P_d que l'on cherche à estimer dynamiquement, justement en fonction de ces contextes. Nous insistons toutefois sur le fait qu'il sera difficile d'établir, à partir de ces résultats, les paramètres intrinsèques liés au contexte objet/objet des réseaux bayésiens.

III.7.3 Résultats sur données réelles

Nous allons maintenant présenter quelques résultats de l'algorithme de détection par invariant proposé dans ce chapitre sur des données réelles. Ces données nous ont été fournies par l'Ecole Nationale Supérieure des Mines de Paris. Elles proviennent d'essais d'acquisitions multicapteurs à l'aide de RTMaps, logiciel d'acquisition et de traitements temps-réel, pour des capteurs installés sur un véhicule circulant en circuit. Le capteur laser utilisé est un IBEO. Nous avons sélectionné à partir de ces données, des acquisitions pour lesquelles le contexte se rapproche d'un environnement autoroutier.

Sur la figure 86, nous donnons un résultat de la segmentation issue de notre algorithme pour l'acquisition 370 des données de l'ENSMP. Nous présentons également sur la figure 87, pour cette

acquisition, l'évolution des accumulations maximales du paragraphe III.6.2.1. Sur la figure 88, des résultats en détection provenant de 4 acquisitions prises au hasard de ce jeu de données télémétriques. Pour ces acquisitions, la zone d'observation a été limitée à $X_{min} = -5m$ et $X_{max} = 5m$, comme indiqué sur la figure 88, de manière à limiter la zone d'observation à la route à l'avant du véhicule.

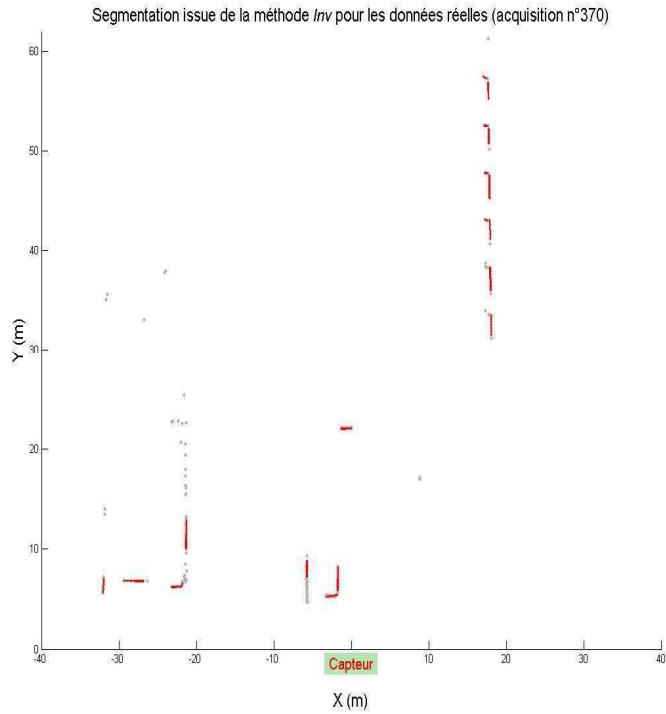


Figure 86 : Segmentation par l'algorithme de détection par invariant sur données réelles.

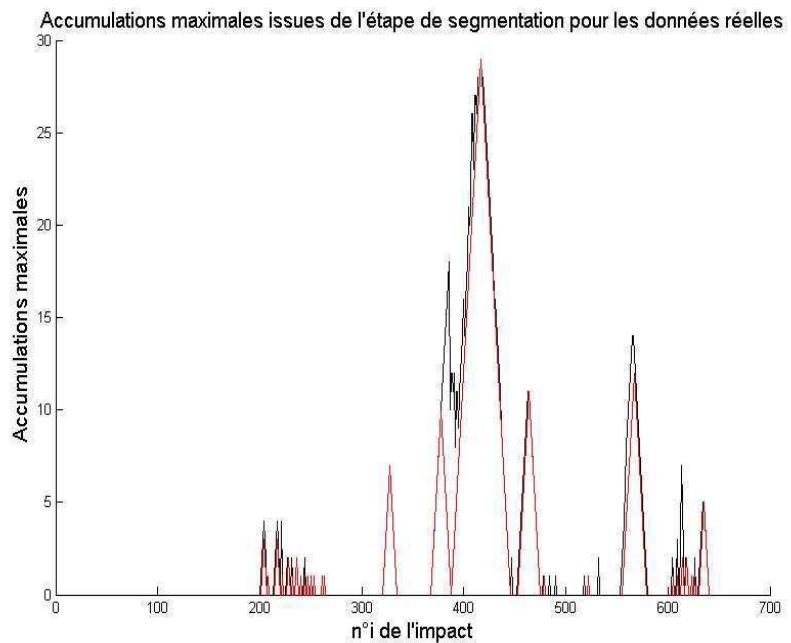


Figure 87 : Evolution des accumulations maximales pour l'acquisition de la figure 86.

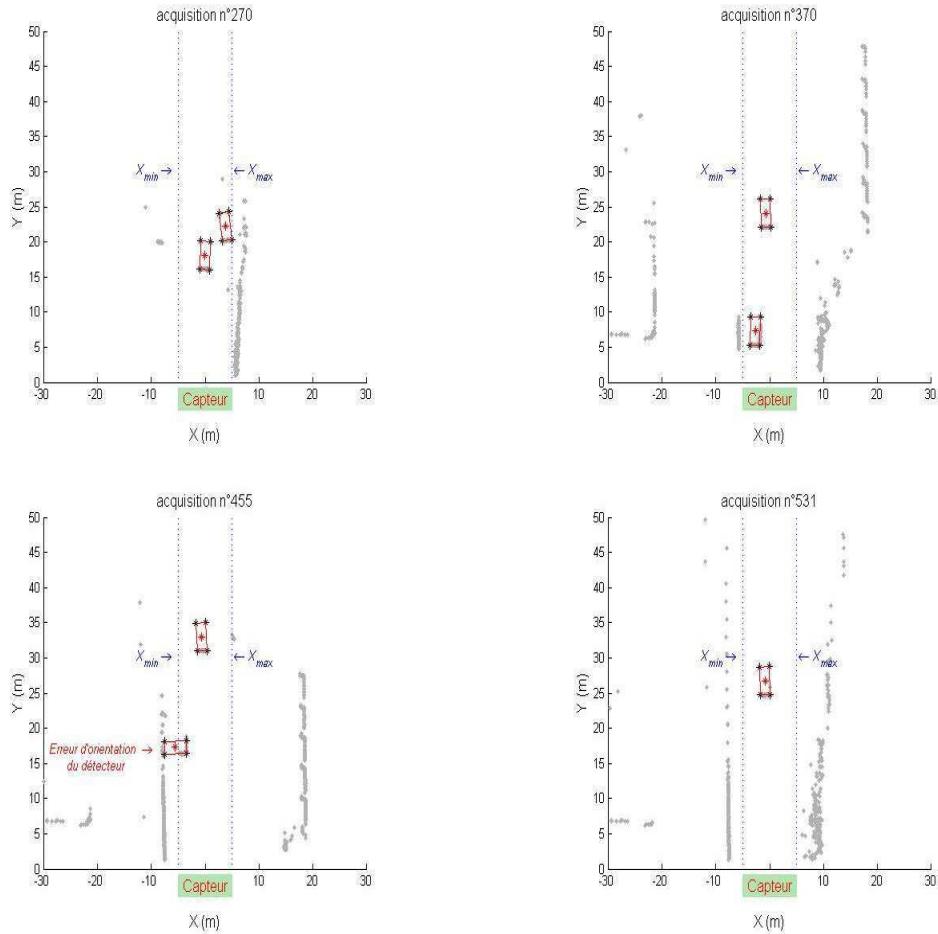


Figure 88 : Détection de véhicules pour différentes acquisitions des données ENSMP.

Les résultats obtenus semblent tout à fait corrects et l'algorithme de détection proposé dans ce chapitre sera utilisé pour l'étape de détection lors du processus de suivi sur données réelles.

III.8 Conclusion

Dans ce chapitre, nous nous sommes intéressés à l'étape de détection pour des mesures provenant d'un télémètre laser. Après avoir rappelé le contexte général de la détection télémétrique, avec notamment un bref rappel sur les principes de détection radar, nous avons insisté sur les difficultés de détecter les objets multiples et spatialement distribués dans la scène d'observation.

Après avoir présenté des méthodes classiques de détection, nous avons proposé un algorithme de détection basé sur des invariants géométriques présents dans la scène. Après l'avoir comparé à deux des algorithmes les plus souvent rencontrés dans la littérature associée à notre problématique, nous avons étudié les performances de cet algorithme vis-à-vis de différents paramètres contextuels. Les performances de cet algorithme en efficacité de détection, en précision et relativement en rapidité sont tout à fait correctes, à la fois sur des données synthétiques issues d'un simulateur que nous avons développé, mais surtout sur des données réelles.

La caractérisation des performances en fonction des paramètres contextuels capteur/objet, *i.e.* la taille de l'objet et la distance entre le capteur et l'objet, nous renforce dans l'idée d'une nécessité d'une détermination dynamique de la probabilité de détection P_d , valeur prépondérante pour l'association par des méthodes de type PDA. Nous pourrons tirer de cette étude des connaissances *a priori* pour les paramètres intrinsèques des réseaux bayésiens que nous allons alors utiliser. Nous avons également étudié le comportement de la qualité de détection par rapport au contexte objet/objet, principalement les occultations entre objets de la scène, et aussi à la perte de visibilité provoquée par la sortie de l'objet du champ d'observation. Même si le lien entre les occultations, la visibilité et la probabilité de détection est plus délicat à établir, nous avons maintenant la certitude que l'efficacité en détection est fortement dépendante de ces variables contextuelles. C'est l'intégration de ces variables dans le processus d'association que nous nous proposons d'établir dans le chapitre suivant.

Chapitre IV

Suivi multi-objets avec intégration du contexte (capteur/objet, objet/objet)

Dans le chapitre III, nous avons proposé une méthode de détection et suivi d'objets qui exploite l'information contextuelle. On a notamment intégré, dans l'étape d'association, des informations sur la scène qui permettent d'affiner la détermination de la probabilité de détection (P_d), élément central dans la méthode d'association probabiliste de données (PDA) employée.

Même si cette approche nécessite de respecter des contraintes de séparabilité spatiale des objets suivis, elle a permis d'obtenir des gains significatifs de performances en estimation et suivi. La méthode employée pour intégrer l'information contextuelle repose sur la mise en œuvre d'un réseau bayésien simple qui exploite les informations relatives capteur/objet pour délivrer une estimation dynamique de cette probabilité de détection, que l'on calcule très souvent hors ligne.

Toutefois, la probabilité de détection qui constitue la probabilité que l'objet soit détecté, nécessite une évaluation globale de la chaîne de détection/estimation. Elle oblige donc, si on souhaite la caractériser plus finement, à revoir l'ensemble de la chaîne de traitement, en évaluant l'impact sur la détection de chaque maillon (capteur, détecteur, pistes).

Dans ce chapitre, on s'intéresse donc plus seulement à la relation capteur/objet mais également à l'interaction objet/objet. En plus de la probabilité de détection, on étudie le pourcentage visible de chaque objet par le capteur et le pourcentage d'occultation de chaque objet par les autres objets présents dans la scène. L'étude de ces points permet d'en tirer bénéfice lors des étapes d'estimation et de suivi. Le calcul du pourcentage d'occultation d'un objet prend en considération tous les objets présents dans la scène ainsi que les caractéristiques du capteur qui est mis en œuvre. En revanche, le pourcentage de visibilité d'un objet par rapport au capteur est déterminé en utilisant une approche probabiliste basée sur un réseau bayésien. Ce calcul prend en compte les caractéristiques du capteur, la distance entre le centre du capteur et le centre de l'objet ainsi que la taille de l'objet. L'utilité de ces probabilités intervient dans la réalisation de la phase d'association temporelle qui est une phase fondamentale pour effectuer un suivi correct.

Une telle approche nécessite également de poser le problème global de la détection en étudiant ses performances dans un cadre multi-objets, comme détaillée dans le chapitre III.

Par ailleurs, afin de prendre en compte l'interaction objet/objet et atteindre ainsi un degré de généralité supérieur dans l'approche développée, l'étape d'association de données est ici réalisée

par la méthode JPDA (Joint Probabilistic Data Association) qui permet d'exploiter les dépendances statistiques de chaque objet présent dans la scène.

IV.1 Intégration du contexte

IV.1.1 Visibilité (dépendance capteur /objet)

L'objectif de la mise en œuvre de cette modélisation (figure 90) est d'estimer le pourcentage de l'objet que le capteur est capable de mesurer lorsque celui-ci se trouve dans le champ de vision. Cette modélisation prend en compte la géométrie de l'objet (taille de l'objet), les limites angulaires de balayage et les coordonnées polaires du centre de l'objet (figure 89). A noter que le centre du repère est ici également lié au capteur.

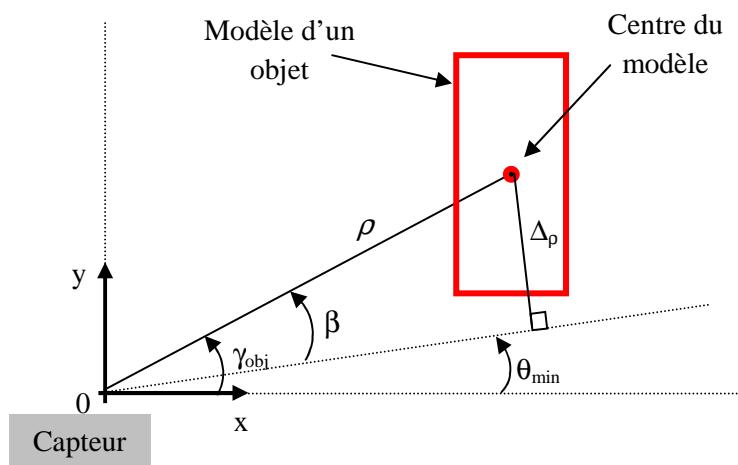


Figure 89 : Modélisation géométrique.

avec γ_{obj} , l'angle entre l'axe du centre du modèle géométrique du capteur et l'axe de X ;

θ_{min} , l'angle minimal de l'ouverture angulaire du capteur ;

$\beta = \gamma_{obj} - \theta_{min}$, la différence de ces 2 angles ;

ρ , la distance entre le centre de l'objet et le capteur ;

$\Delta\rho$ la distance entre le centre du modèle géométrique du l'objet et l'axe de l'angle limite minimal de l'ouverture angulaire du capteur.

Le réseau bayésien (figure 90) utilisé ici est un réseau bayésien hybride parce qu'il contient des variables continues (Distance) et discrètes (Taille, Angle, Visibilité). Le résultat attendu en sortie du réseau $P(Visibilité|Taille, Distance, Angle)$ est calculé par une fonction « probit » comme détaillée ci-dessous. Elle est définie en fonction de la distance, de la taille et de l'angle entre l'axe du centre de l'objet et l'axe de X.

Cette étape permet de connaître la visibilité de l'objet à chaque instant, c'est-à-dire la capacité que le capteur a de mesurer l'objet (indépendamment des liens entre les objets présents). Lorsque l'objet

sort complètement et définitivement du champ de vision du capteur (la visibilité tombe à zéro). Dans ce cas, l'objet n'est plus suivi.

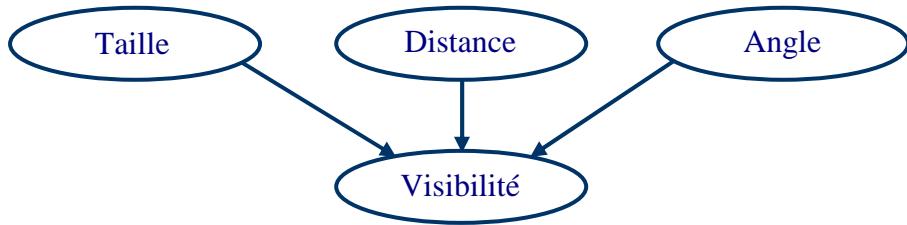


Figure 90 : Modèle bayésien pour le calcul de visibilité des objets.

La fonction utilisée pour calculer la probabilité de visibilité est dérivée d'une fonction « probit ». Elle permet d'estimer la probabilité de visibilité d'objet sachant qu'on connaît sa taille, la distance qui le sépare du capteur et sa position angulaire par rapport à l'axe de X. La fonction est décrite par :

$$P(\text{Visibilité} / \text{Taille}, \text{Distance}, \text{Angle}) = \Phi\left(\frac{\Delta\rho + \mu_{\Delta\rho}}{\sigma_{\Delta\rho}}\right),$$

où $\Delta\rho$: la perpendiculaire menant du centre de l'objet à l'axe de l'angle limite

$$\Delta\rho = \rho \cdot \sin(\beta) \text{ avec } \beta = \begin{cases} \gamma_{obj} - \theta_{\min} & \text{angle limite minimal du capteur} \\ \theta_{\max} - \gamma_{obj} & \text{angle limite maximal du capteur} \end{cases} \begin{matrix} & \text{si } \gamma_{obj} > 0 \\ & \text{si } \gamma_{obj} < 0 \end{matrix}$$

$$\sigma_{\Delta\rho} = \frac{L}{4}, \text{ où } L \text{ est la longueur de l'objet.}$$

La valeur $\mu_{\Delta\rho} = -0.05$ est définie par une heuristique.

IV.1.2 Occultation (dépendance objet/objet)

L'objectif est maintenant d'évaluer le pourcentage d'occultation de l'objet suivi par les autres objets de la scène.

En effet, l'occultation d'un objet doit nécessairement être prise en compte lors de l'étape d'association car elle conditionne directement la probabilité que l'on a de détecter l'objet dans les mesures. Cette probabilité est en effet essentielle à une association efficace de chaque objet de la scène.

La méthodologie utilisée pour atteindre cet objectif est décrite par :

- prédition des états des tous les objets en cours de suivi (pistes) ;
- implantation du modèle géométrique choisi par chacun des objets : on calcule ainsi les extrémités du modèle et les angles extrêmes correspondants (θ_{i_min} , θ_{i_max}), $i = 1, \dots, nb_objet$.
- on divise l'ouverture angulaire du capteur en intervalles égaux dont la largeur est la résolution angulaire. Dans notre cas, l'ouverture angulaire vaut 160° (entre 10° et le 170°) et la résolution angulaire est de $0,25^\circ$, ce qui fait 641 intervalles.

- pour chaque objet i ($i = 1, \dots, nb_objet$), on construit la fonction O_i évaluant son occupation angulaire (dans le champ de vision).
- soit l'ensemble Ω_θ des positions angulaires que l'on mesure. $\Omega_\theta = \{\theta_{\min}, \theta_{\min} + \Delta\theta, \theta_{\min} + 2\Delta\theta, \dots, \theta_{\max}\}$ où $[\theta_{\min}, \theta_{\max}]$ est l'ouverture angulaire du capteur et $\Delta\theta$ sa résolution angulaire.
- la fonction O_i est définie pour chaque $\theta_j \in \Omega_\theta$ de la manière suivante :

$$O_i(\theta_j) = \begin{cases} \rho_i & \text{si } \theta_{i_min} \leq \theta_j \leq \theta_{i_max} \\ \rho_{\max} & \text{sinon} \end{cases}$$

où ρ_{\max} est la portée maximale du capteur.

- le taux d'occultation de chaque objet est alors évalué de la manière suivante :
 - o on construit la fonction globale d'occupation angulaire (de tous les objets) :

$$O(\theta_j) = \begin{cases} \rho_{\min}(\theta_j) & \text{si } \rho_{\min}(\theta_j) \neq \rho_{\max} \\ \rho_{\min}(\theta_j) + 1 & \text{sinon} \end{cases}$$

avec $\rho_{\min}(\theta_j) = \min(O_1(\theta_j), O_2(\theta_j), \dots, O_{nb_obj}(\theta_j))$ pour $\theta_j \in \Omega_\theta$.

- o on calcule les positions angulaires occupées par l'objet O_i qui ne sont pas occultées par les autres objets, par la différence entre la fonction globale O et la fonction O_i qui évalue l'occupation angulaire de l'objet i , indépendamment des autres objets :

$$D_i(\theta_j) = O(\theta_j) - O_i(\theta_j) \text{ pour } \theta_j \in \Omega_\theta.$$

- o la proportion non masquée de l'objet i est donnée par :

$$P_i = \frac{\text{card}\{D_i(\theta_j) / D_i(\theta_j) = 0, \forall \theta_j \in \Omega_\theta\}}{\text{card}\{O_i(\theta_j) / O_i(\theta_j) \neq \rho_{\max}, \forall \theta_j \in \Omega_\theta\}}.$$

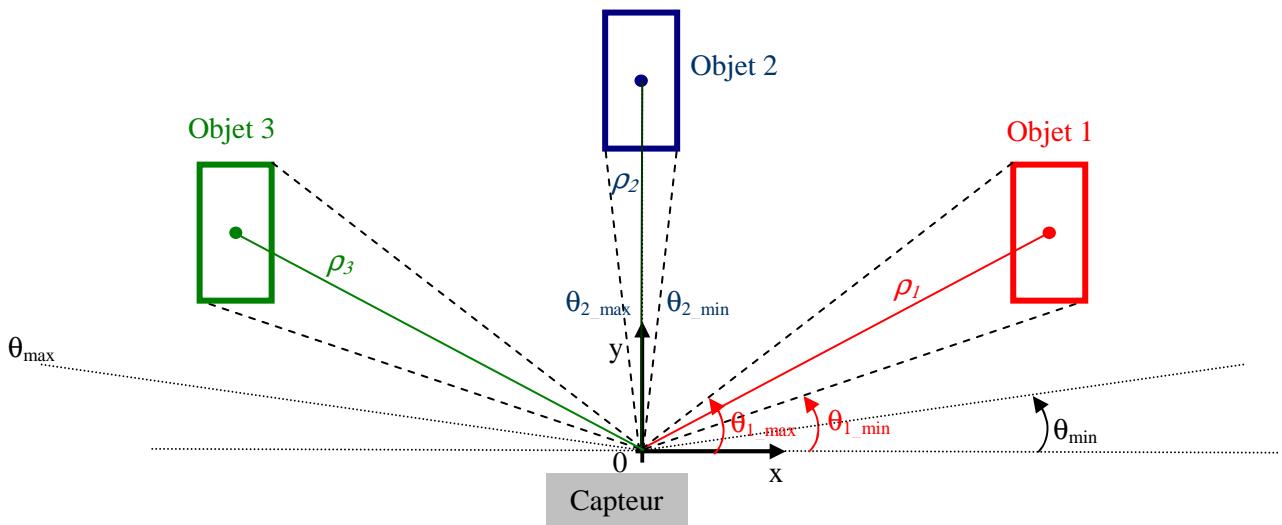


Figure 91 : Positionnement de l'objet dans le repère et les angles extrêmes de chaque objet.

Les figures (figure 92, figure 93, figure 94, figure 95) reprennent les différentes étapes de ce calcul pour une acquisition donnée (figure 92).

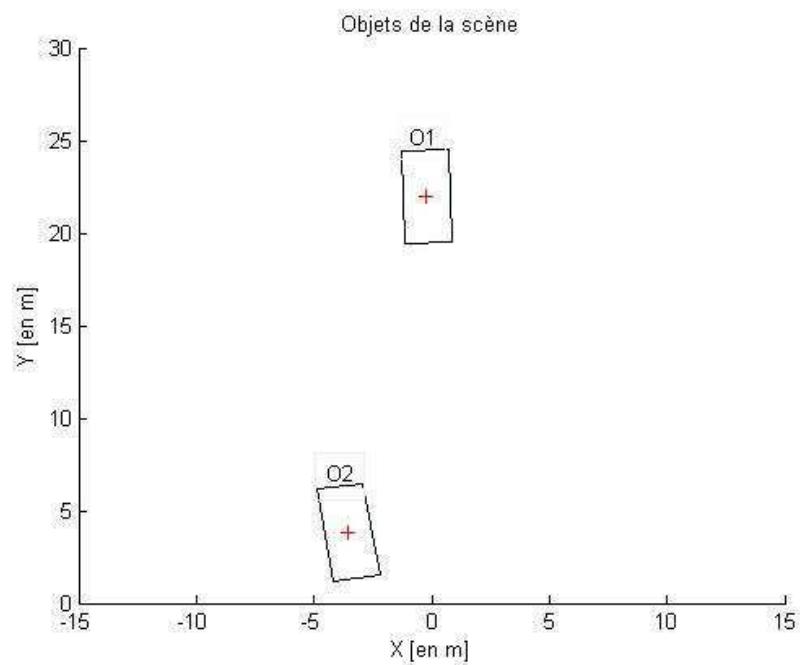


Figure 92 : Objets de la scène à un instant donné

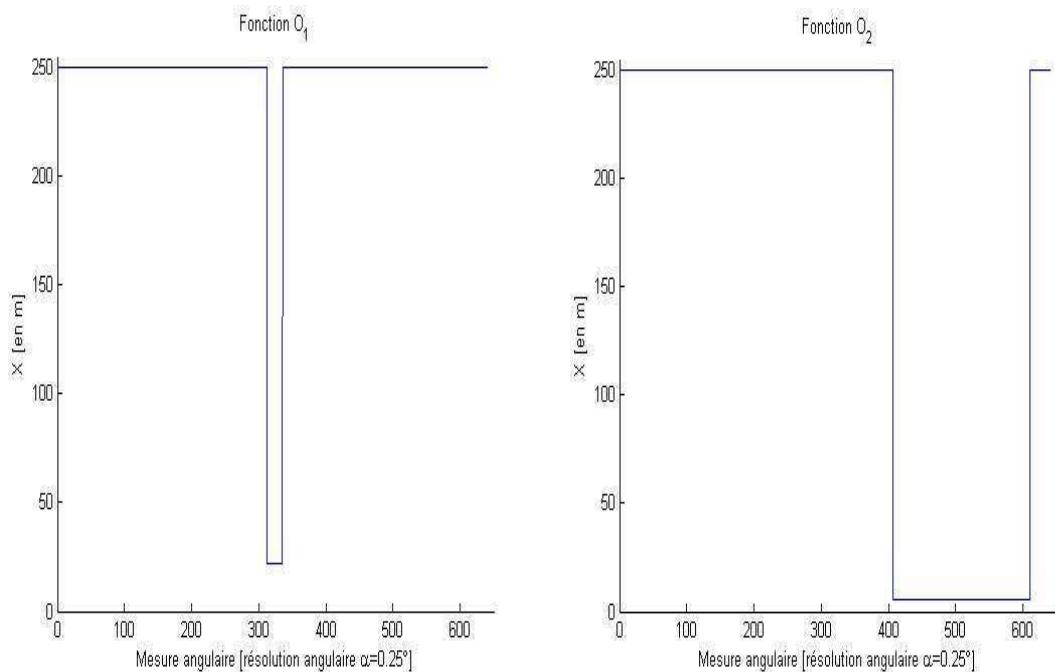


Figure 93 : Fonctions O_1 et O_2 des objets sur la figure 92.

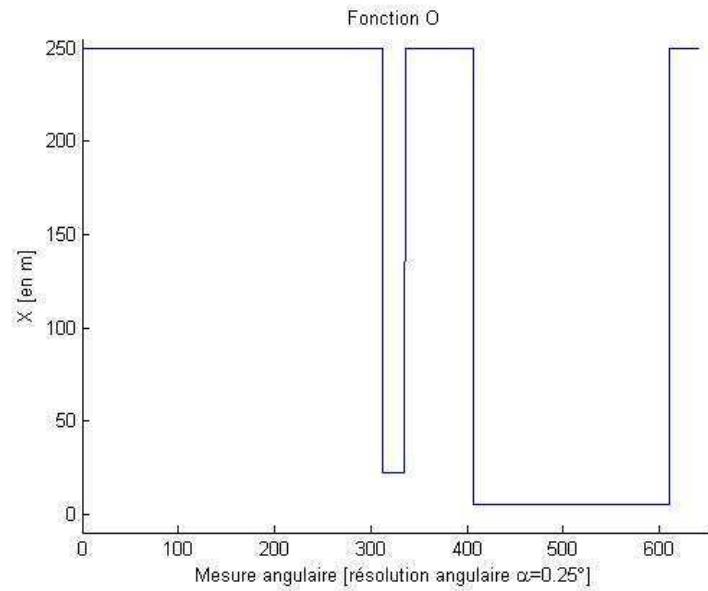


Figure 94 : Fonction globale O des fonctions O_1 et O_2 de la figure 93.

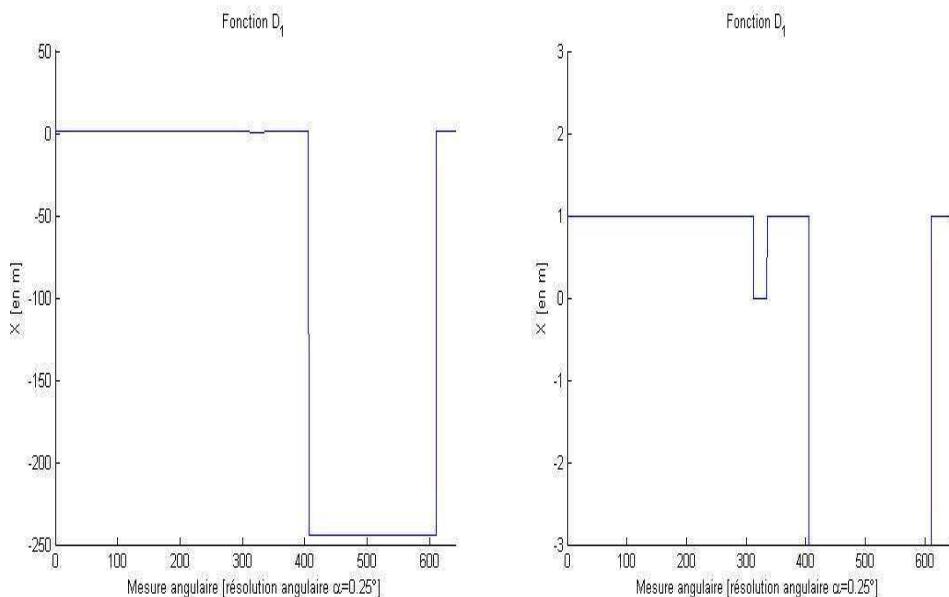


Figure 95 : Fonction D_1 entre la fonction globale O (figure 94) et la fonction O_1 (figure 93).

Sur la partie droite de la figure 95, nous détaillons la zone d'apparition angulaire de l'objet 1 (passage par 0 de la fonction D_1).

Cette évaluation permet de connaître à chaque instant la proportion visible de chaque objet et ainsi d'affiner la détermination de la probabilité de détection.

IV.1.3 Déetectabilité

Outre la prise en compte dans le processus global d'intégration du contexte de la visibilité et de l'occlusion, il est important de conserver l'étape d'évaluation de la détectabilité (comme dans le chapitre précédent).

La détectabilité représente la capacité que le capteur a de mesurer un objet en égard à ses caractéristiques techniques (quantification angulaire/distance).

On retrouve donc ici le même réseau bayésien que dans le chapitre II (figure 96). La détermination de cette grandeur se fait par deux méthodes. Dans la première méthode, on considère que les variables sont discrètes, dans ce cas là, on utilise le réseau bayésien (figure 96) et on induit par inférence la probabilité de la détectabilité de l'objet. Les tables des probabilités des variables Taille et Distance sont calculées selon des fonctions linéaires. Une table des probabilités conditionnelles reliant les variables Taille et Distance à la variable Détectabilité est nécessaire et est définie une fois au début de l'expérience pour réaliser l'inférence.

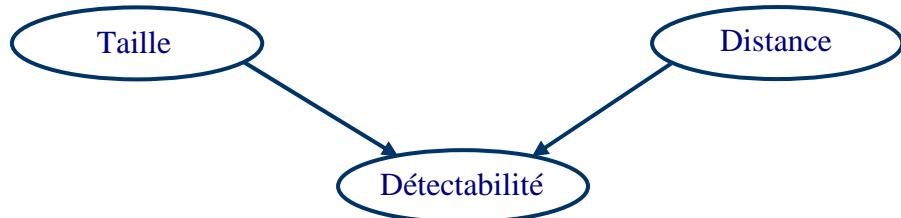


Figure 96 : Réseau bayésien pour le calcul de la détectabilité.

Règles utilisées pour le calcul des tables des probabilités a priori (Distance et Taille).

- $Taille_{min}=0.3m$, $Taille_{max}=2m$
Si $Taille_{obj} \geq Taille_{max}$ alors $Pr_{Taille_grande}=0.9$.
- $Dist_{min}=1m$, $Dist_{max}=250m$
Si $Dist_{Cap_obj} < Dist_{min}$ alors $Pr_{Distance_courte}=0.9$.
Si $Dist_{Cap_obj} > Dist_{max}$ alors $Pr_{Distance_longue}=0.9$.
Si $Dist_{Cap_obj} \geq Dist_{min}$ et $Dist_{Cap_obj} \leq Dist_{max}$ alors
 $Pr_{Distance_courte}=1-(Dist_{Cap_obj}-Dist_{min})/Dist_{max}$.

Dans la seconde méthode, on considère que la variable distance est continue et on utilise une fonction de « probit » qui nous permet d'estimer le niveau de détectabilité de l'objet. Celle-ci exige une estimation d'une moyenne et un écart-type pour l'appliquer. Comme la portée du capteur utilisé est de l'ordre de 250m et la taille de l'objet est connu ici, on a estimé que la valeur de la moyenne est de l'ordre de 150m et l'écart-type est de l'ordre de 60m/s. La figure 97 montre la courbe générale de visibilité qui est estimée en fonction de toutes les valeurs possibles des distances.

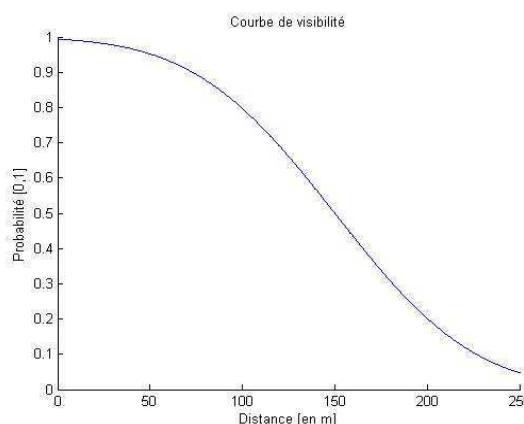


Figure 97 : Courbe de la détectabilité $P(Détectabilité/Distance=d)$

La fonction « probit » qu'on avait utilisé est de la forme suivante :

$$P(\text{detectabilite}/\text{Distance}=d)=\Phi\left((-\rho+\mu)/\sigma\right),$$

où ρ est la distance entre le centre de l'objet et le centre du capteur, μ est la moyenne estimée et σ son écart type.

On constate bien que la détectabilité diminue à mesure que la distance augmente et vice-versa. L'estimation des valeurs de la moyenne et de l'écart-type dépend de la taille de l'objet.

IV.1.4 Estimation de la probabilité de détection

Après avoir évalué les visibilités et détectabilités de chaque objet de la scène ainsi que les occultations des objets entre eux, on exploite ces grandeurs dans un réseau bayésien (figure 98) pour déterminer, à chaque instant d'estimation, une valeur de la probabilité de détection P_d .

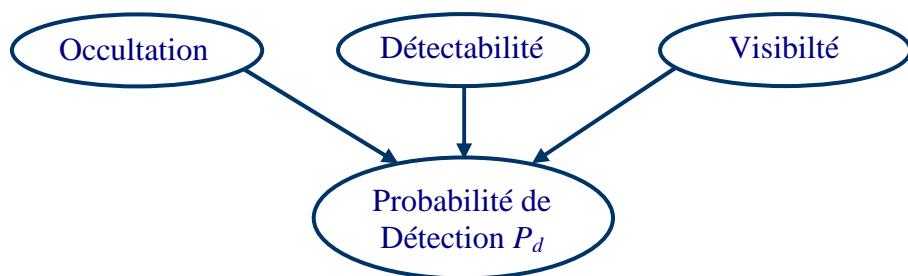


Figure 98 : Réseau bayésien pour le calcul de la confiance.

Ce réseau bayésien nous permet d'intégrer le contexte capteur/objet (Déetectabilité, Visibilité), mais aussi le contexte objet/objet par le biais des occultations. Chacun des nœuds du réseau bayésien est défini par deux états ; Déetectabilité {déTECTé, non_déTECTé}, Occultation {occulté, non_occulté}, Visibilité {visible, non_visible} et Probabilité_Détection {oui, non}. Les tables des probabilités des nœuds parents sont calculées *a priori*. En revanche, la table des probabilités conditionnelles (Tableau 11) relie les nœuds parents {Déetectabilité, Occultation et Visibilité} à leur fils selon les règles suivantes :

Si $(P(\text{Occ}=o)=0 \text{ et/ou } P(\text{Vis}=v)=0 \text{ et/ou } P(\text{DT}=d)=0)$

Alors

$$P(\text{DT_R} | \text{Occ}, \text{Vis}, \text{DT})=0 \text{ et } P(\neg\text{DT_R} | \text{Occ}, \text{Vis}, \text{DT})=1- P(\text{DT_R} | \text{Occ}, \text{Vis}, \text{DT})$$

Sinon

$$P(\text{DT_R} | \text{Occ}, \text{Vis}, \text{DT})=\delta_{\text{occ}} \cdot P(\text{Occ}) + \delta_{\text{vis}} \cdot P(\text{Vis}) + \delta_{\text{DT}} \cdot P(\text{DT})$$

$$P(\neg\text{DT_R} | \text{Occ}, \text{Vis}, \text{DT})=1- P(\text{DT_R} | \text{Occ}, \text{Vis}, \text{DT})$$

FinSi

Avec δ_{occ} , δ_{vis} , δ_{DT} établi par heuristique, avec cependant $\delta_{\text{occ}}+\delta_{\text{vis}}+\delta_{\text{DT}}=1$;

Pour simplifier l'écriture des noms des nœuds et leurs états, on utilise pour la table des probabilités conditionnelles, les notations suivantes :

- pour les noms des variables : *Occ* pour Occultation, *Vis* pour Visibilité, *DT* pour Déetectabilité et *P_d* pour Probabilité de détection ;

- pour les noms des états : o pour occulté, nno pour non_occulté, v pour visible, nnv pour non_visible, d pour détecté et nnd : non_détecté.

Occ	o				nno			
Vis	v		nnv		v		nnv	
DT	d	nnd	d	nnd	d	nnd	d	nnd
P_d	oui	P_{11}	P_{12}	P_{13}	P_{14}	P_{15}	P_{16}	P_{17}
	non	P_{21}	P_{22}	P_{23}	P_{24}	P_{25}	P_{26}	P_{27}

Tableau 11: Tables des probabilités conditionnelles $P(P_d | Occ, Vis, DT)$.

où $P_{11}=P(P_d=\text{oui} | Occ=o, Vis=v, DT=d)$

et $P_{21}=P(P_d=\text{non} | Occ=o, Vis=v, DT=d)$

Au regard des descriptions partielles de chaque composante intervenant dans la détermination de la probabilité de détection, nous présentons dans la Figure 99 le réseau bayésien complet d'intégration du contexte (capteur/objet, objet/objet), qui sera utilisé par la suite.

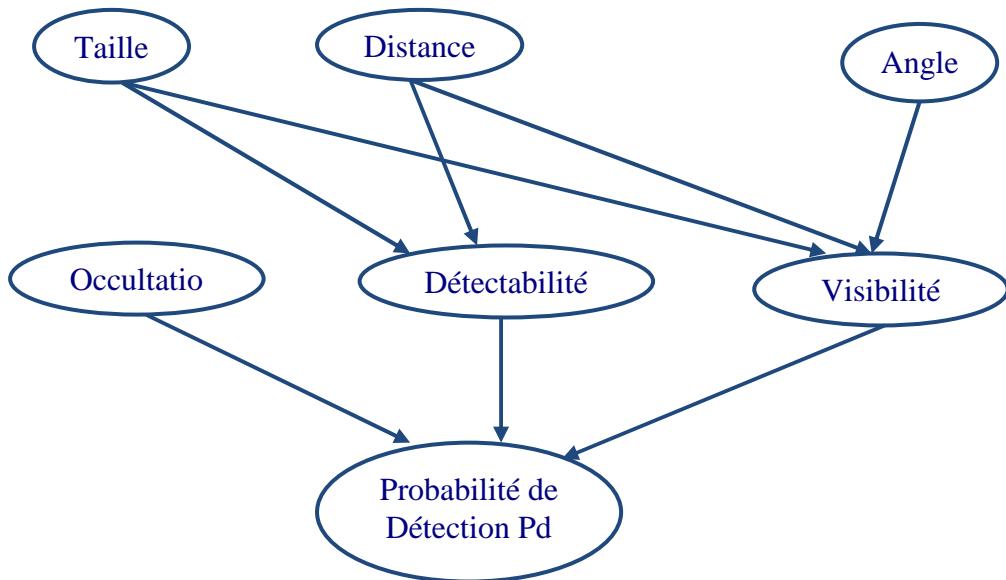


Figure 99: Modèle général du réseau bayésien.

IV.2 Application des réseaux bayésiens à l'estimation et du suivi par une approche JPDA

Cette méthode de mise en correspondance prend simultanément en considération toutes les pistes et toutes les observations pour effectuer la phase d'association pistes-observations. Elle traite le cas des chevauchements entre différentes pistes, c'est-à-dire quand il y a des observations affectées à plus d'une région de validité. Dans ce cas, il est plus robuste de prendre en compte toutes les hypothèses possibles pour associer les observations aux pistes. La construction des hypothèses sera réalisée sur la base suivante : une piste est associée à une seule et unique observation et une observation ne peut être à l'origine que d'une piste.

Les étapes principales de cet algorithme se résument ainsi :

- **observations** : à chaque balayage, les objets sont construits à partir de l'ensemble des mesures du capteur (radar, télémètre ou IBEO). Cette phase de traitement des observations est effectuée par une méthode d'association spatiale (ou détection).
- **pistes prédictes** : elles sont obtenues par l'étape de prédiction d'un filtre de Kalman réalisée sur toutes les pistes de l'instant précédent.
- **association** : cette phase crée une matrice d'association $M = (c_{ij})$ dont les lignes représentent le nombre de pistes et les colonnes représentent le nombre d'observations où $c_{ij} = \begin{cases} 1 & \text{si } d_{ij}^2 \leq \gamma \\ 0 & \text{sinon} \end{cases}$ et d_{ij}^2 la distance de Mahalanobis. γ est le *seuil de décision* dont sa valeur dépend à la fois d'une probabilité d'être l'observation dans la région de validité de la piste en question et de la dimension de l'espace. La relation est donnée par :

$$d_{ij}^2 = (Z_j(t) - \hat{Z}(t|t-1))^T S_{ij}^{-1} (Z_j(t) - \hat{Z}(t|t-1))$$

où S_{ij} est la matrice d'innovation de la piste i avec l'observation Z_j et est définie par $S_{ij} = H_t P_i(t|t-1) H_t^T + R_j(t)$ avec $R_j(t)$, la matrice de covariance d'erreur autour de l'observation Z_j . Elle est calculée en fonction des erreurs commises sur la distance ρ et l'angle θ puisque les mesures délivrées par le système de perception sont en coordonnées polaires (ρ, θ) .

La *région de validité* est une ellipse dont le centre est la position prédictive de la piste et les axes sont formés à partir de la matrice d'innovation S_{ij} du filtre de Kalman. Cette dernière matrice prend en considération les incertitudes autour de la position prédictive et les nouvelles observations (observation par observation).

- **vectorisation** : cette étape est construite à partir de l'étape précédente. C'est la construction pour chaque piste d'une matrice qui récapitule les associations possibles de la piste et d'un vecteur qui contient les numéros des pistes pour lesquelles il n'a pas été trouvé d'associations. Chaque ligne de ces matrices comporte successivement le numéro de la piste, le numéro d'observation associée, le PDF (Probability Density Function) entre la piste et

l'observation et le volume de la région de validité de la piste. Le nombre de lignes de cette matrice est identique au nombre d'observations associées à la piste.

Le volume de la région de validité d'une piste i avec une observation Z_j est obtenu par la

$$\text{formule suivante : } V_{ij} = \pi \cdot \gamma^{N_z/2} \cdot \sqrt{|S_{ij}|},$$

avec N_z la dimension de l'espace et « π » parce qu'on est dans un espace à deux dimensions.

- **groupement des pistes dans des groupes** : cette étape, à partir des résultats de l'étape précédente, traite du regroupement des pistes qui ont des observations se retrouvant dans la partie commune de leur région de validité (cas d'un chevauchement de ces régions). La figure 100 illustre le résultat d'un regroupement de pistes à un instant donné pour lequel trois pistes sont regroupées dans un même groupe 1, une piste est affectée au groupe 2.

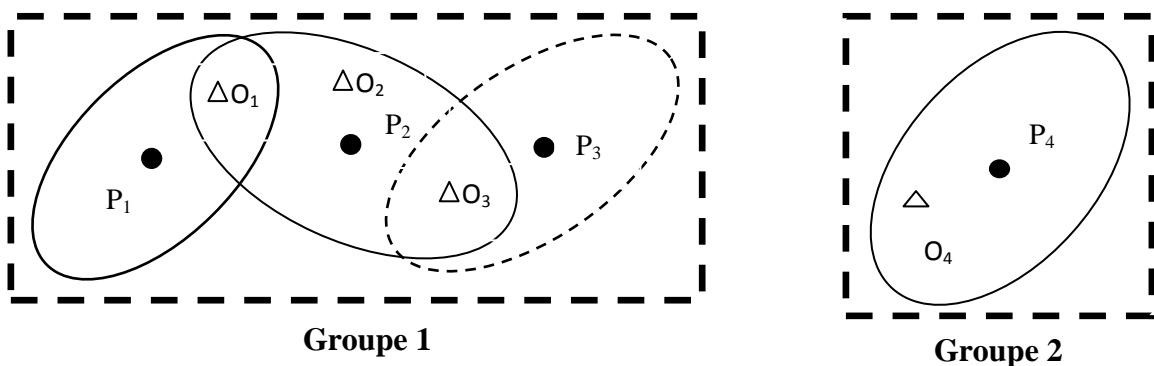


Figure 100 : Exemple de regroupement des pistes dans des groupes.

- **construction des hypothèses et calcul de la probabilité des hypothèses d'un groupe** : la construction des hypothèses pour chaque groupe de pistes obtenues dans l'étape précédente est nécessaire pour le calcul des probabilités d'associations (étape suivante) qui participeront à la phase de correction des états des pistes. On considère pour chaque piste le cas particulier de « **zéro observation** ». Chaque hypothèse est construite de la manière suivante : le cas particulier « **zéro observation** » peut être associé à plusieurs pistes, par contre une observation ne peut être à l'origine que d'une piste et réciproquement une piste est associée à une seule et unique observation. La probabilité de chaque hypothèse est calculée selon les étapes suivantes.
 - calcul de la probabilité de détectabilité pour chaque piste à partir du réseau bayésien.
 - calcul de la densité spatiale du groupe des pistes par la formule suivante :

$$\beta = \frac{\sum_{i=1}^{m_k} n_i}{\sum_{i=1}^{m_k} V_i}$$

où n_i le nombre des observations qui tombent dans la région de validité de la piste i ;

V_i le volume de la région de validité de la piste i avec toutes les observations associées qui est définie par $V_i = \sum_{j=1}^{n_i} \alpha_{ij} \cdot V_{ij}$, où α_{ij} est la probabilité d'association entre la piste i et l'observation Z_j ;
 m_k le nombre des pistes groupées.

- c. calcul de la densité de probabilité entre la piste i et l'observation associée j de la manière suivante :

$$g_{ij} = \frac{e^{-\frac{d_{ij}^2}{2}}}{(2\pi)^{N_z/2} \sqrt{|S_{ij}|}} \text{ où}$$

où d_{ij}^2 la distance de Mahalanobis entre la piste i et l'observation associée j ;
 N_z la dimension de l'espace ;
 S_{ij} la matrice d'innovation de la piste i avec l'observation Z_j .

- d. calcul des probabilités d'associations :

La probabilité « zéro observation associée à la piste i » est déterminée par $\beta(1 - P_d^i)$.

La probabilité « l'observation j est associée à la piste i » est déterminée par $P_d^i g_{ij}$. La probabilité de détection de l'objet i (P_d^i) est obtenue par l'approche probabiliste basée sur le réseau bayésien.

Le calcul de la probabilité d'une hypothèse se fait par la multiplication des probabilités d'associations de chaque piste pour cette hypothèse. Le calcul des probabilités de toutes les hypothèses d'un groupe sera suivi d'une étape de normalisation des probabilités.

- **calcul des probabilités d'associations pour chacune des pistes.** Pour une piste, on extrait de la matrice des hypothèses les probabilités des hypothèses pour chaque observation de cette piste. La probabilité d'association d'une observation à une piste est ensuite obtenue par l'addition de toutes les probabilités des hypothèses extraites pour cette observation.

Dans notre implantation logicielle, la probabilité d'association de l'observation j à la piste i est déterminée par une somme de probabilités des hypothèses dans lesquelles cet événement se produit. Elle est calculée de la manière suivante : $p_{ij} = \sum_{H_l \in T_j} P(H_l)$,

$$j = 1, \dots, n_i(t), i = 1, \dots, N_p$$

Où T_j est l'ensemble des indices de toutes les hypothèses, ce qui inclut l'événement mentionné ci-dessus, $n_i(t)$ est le nombre des observations trouvées dans la région de validité de la piste i et N_p est le nombre des pistes dans un groupe.

- **correction des états des pistes qui ont des associations :** cette phase de correction est réalisée par la succession d'équations suivantes :

- 1) détermination des coefficients : $\alpha_{i0} = p_{i0}$ et $\alpha_i = \{p_{ij}\}_{j=1}^{m_i}$ où m_i est le nombre des observations associées à la piste à l'instant t , i est le numéro de la piste,

2) correction de l'état :

$$\hat{X}_i(t|t) = \alpha_{i0} \hat{X}_i(t|t-1) + \sum_{j=1}^{m_t} \alpha_{ij}(t) \hat{X}_{ij}(t|t)$$

$$\text{où : } \hat{X}_{ij}(t|t) = \hat{X}_i(t|t-1) + K_{ij}(t) \tilde{Z}_{ij}(t) ,$$

$$\text{avec : } K_{ij}(t) = P_i(t|t-1) H_t^T S_{ij}^{-1}(t) \text{ et } \tilde{Z}_{ij}(t) = Z_j(t) - H_t \hat{X}_i(t|t-1)$$

$$\text{et : } S_{ij}(t) = H_t P_i(t|t-1) H_t^T + R_j(t)$$

où R_j , $j=1, \dots, m_k$ sont les matrices de covariances d'erreurs des observations validées.

3) correction des erreurs d'estimation

$$P_i(t|t) = \alpha_{i0}(t) P_i(t|t-1) + (1 - \alpha_{i0}(t)) P_i^c(t|t) + \tilde{P}_i(t|t)$$

$$\text{avec : } P^c(t|t) = (I - K_i(t) H_t) P_i(t|t-1)$$

$$\text{où : } K_i(t) = \sum_{j=1}^{m_t} \alpha_{ij} K_{ij}(t)$$

$$\text{et } \tilde{P}_i(t|t) = \sum_{j=1}^{m_t} \alpha_{ij}(t) K_{ij}(t) \tilde{Z}_{ij}(t) \tilde{Z}_{ij}^T(t) K_{ij}^T(t) - \left(\sum_{j=1}^{m_t} \alpha_{ij}(t) K_{ij}(t) \tilde{Z}_{ij}(t) \right) \left(\sum_{j=1}^{m_t} \alpha_{ij}(t) K_{ij}(t) \tilde{Z}_{ij}(t) \right)^T$$

L'estimation du vecteur d'état de la piste i $\hat{X}_i(t|t)$ tient compte de toutes les observations fournies par le système de perception jusqu'à l'instant t , ainsi que l'estimation de la matrice de covariance de l'erreur $P_i(t|t)$

- **création des pistes pour les observations qui n'ont pas été associées à des pistes existantes** : cette dernière étape crée une piste pour chacune des observations non associées.

Afin d'illustrer cet algorithme, nous considérons maintenant le cas où une ou plusieurs observation(s) n'est (ne sont) associée(s) à aucune piste. La figure 101 montre ce cas, puisque l'observation O_5 n'est associée à aucune piste.

Dans cet exemple, les étapes de l'algorithme JPDA sont recalculées pour l'ensemble des groupes et observation isolée :

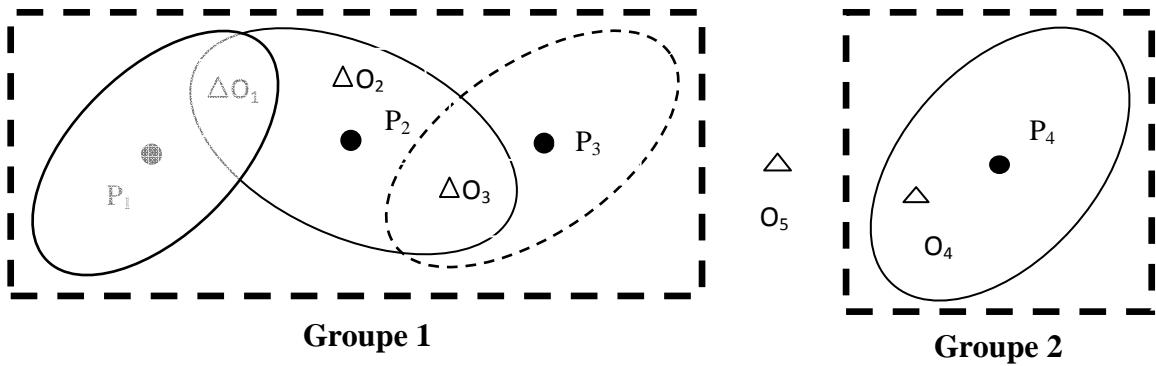


Figure 101 : Illustration d'une observation non associée à des pistes et groupes.

- étape 1 **«observations»** : soient $(o_1, o_2, o_3, o_4, o_5)$ les observations à l'instant courant (voir figure 101).
- étape 2 **«pistes prédictives»** : soient (P_1, P_2, P_3, P_4) les pistes prédictives de l'instant précédent.
- étape 3 **«association»** : la matrice d'association entre les pistes et observations :

$$mat_association = \left(\begin{array}{ccccc} & \overbrace{o_1 \quad o_2 \quad o_3 \quad o_4 \quad o_5}^{\text{Observations}} & & & \\ & \left(\begin{array}{ccccc} 1 & 0 & 0 & 0 & 0 \end{array} \right) & P_1 & \left(\begin{array}{ccccc} 1 & 1 & 1 & 0 & 0 \end{array} \right) & P_2 \\ & \left(\begin{array}{ccccc} 0 & 0 & 1 & 0 & 0 \end{array} \right) & P_3 & \left(\begin{array}{ccccc} 0 & 0 & 0 & 1 & 0 \end{array} \right) & P_4 \end{array} \right) \text{Pistes},$$

- étape 4 **«Vectorisation»** : pour chaque piste, la matrice récapitulant les associations possibles de la piste est construite à partir de la matrice d'association de la façon suivante $mat_piste_numpiste_obs_ass = [\text{numéro de la piste}, \text{numéro d'observation associée}, \text{PDF}, \text{Volume}]$. En revanche, le vecteur qui contient les numéros des pistes qui n'ont pas des associations n'est ici pas construit car il n'y a pas de pistes sans association pour cet exemple particulier.

Les matrices ainsi construites sont les suivantes :

$$mat_piste_1_obs_ass = \begin{bmatrix} 1 & 1 & g_{11} & V_1 \end{bmatrix}$$

$$mat_piste_2_obs_ass = \begin{bmatrix} 2 & 1 & g_{21} & V_2 \\ 2 & 2 & g_{22} & V_2 \\ 2 & 3 & g_{23} & V_2 \end{bmatrix}$$

$$mat_piste_3_obs_ass = \begin{bmatrix} 3 & 3 & g_{33} & V_3 \end{bmatrix}$$

$$mat_piste_4_obs_ass = \begin{bmatrix} 4 & 4 & g_{44} & V_4 \end{bmatrix}.$$

- étape 5 **«groupement des pistes»** : la matrice d'association montre que l'observation o_1 est associée à la piste P_1 et à la piste P_2 , qui sont alors regroupés dans un groupe G_1 . On constate de même que l'observation o_3 est associée à la fois à P_2 et à P_3 , par conséquent P_3 est intégrée au groupe G_1 qui contient déjà les P_1 et P_2 . P_4 n'a pas d'observation «en

commun» avec la région de validité d'une autre piste, un second groupe contenant P_4 est alors construit. Les deux groupes construits sont les suivants :

$$\begin{aligned} \text{groupe_1} &= \{ \text{mat_piste_1_obs_ass}, \text{mat_piste_2_obs_ass}, \text{mat_piste_3_obs_ass} \} \\ \text{groupe_2} &= \{ \text{mat_piste_4_obs_ass} \} \end{aligned}$$

- étape 6 «**construction des hypothèses**» : la construction des hypothèses du groupe 1 selon la règle définit plus haut (détails de l'approche JPDA) permet de construire le tableau suivant :

Piste 1		Piste 2		Piste 3	
N° obs. associées	PDF Correspondante	N° obs. associées	PDF Correspondante	N° obs. associées	PDF Correspondante
0	$\beta(1 - P_d^1)$	0	$\beta(1 - P_d^2)$	0	$\beta(1 - P_d^3)$
1	$P_d^1 g_{11}$	1	$P_d^2 g_{21}$	3	$P_d^3 g_{33}$
		2	$P_d^2 g_{22}$		
		3	$P_d^2 g_{23}$		

On en déduit la matrice des hypothèses et les probabilités associées à chaque hypothèse :

Hypothèses	Piste1	piste2	piste3	PDF des hypothèses
H ₁	0	0	0	$\beta(1 - P_d^1) \beta(1 - P_d^2) \beta(1 - P_d^3)$
H ₂	0	0	3	$\beta(1 - P_d^1) \beta(1 - P_d^2) P_d^3 g_{33}$
H ₃	0	1	0	$\beta(1 - P_d^1) P_d^2 g_{21} \beta(1 - P_d^3)$
H ₄	0	1	3	$\beta(1 - P_d^1) P_d^2 g_{21} P_d^3 g_{33}$
H ₅	0	2	0	$\beta(1 - P_d^1) P_d^2 g_{22} \beta(1 - P_d^3)$
H ₆	0	2	3	$\beta(1 - P_d^1) P_d^2 g_{22} P_d^3 g_{33}$
H ₇	0	3	0	$\beta(1 - P_d^1) P_d^2 g_{23} \beta(1 - P_d^3)$
H ₈	1	0	0	$P_d^1 g_{11} \beta(1 - P_d^2) \beta(1 - P_d^3)$
H ₉	1	0	3	$P_d^1 g_{11} \beta(1 - P_d^2) P_d^3 g_{33}$
H ₁₀	1	2	0	$P_d^1 g_{11} P_d^2 g_{23} \beta(1 - P_d^3)$
H ₁₁	1	2	3	$P_d^1 g_{11} P_d^2 g_{22} P_d^3 g_{33}$
H ₁₂	1	3	0	$P_d^1 g_{11} P_d^2 g_{23} \beta(1 - P_d^3)$
Matrice des hypothèses				

- étape 7 «**calcul des probabilités d’associations pour chacune des pistes**» : nous donnons ci-après l’exemple de ce calcul pour la probabilité de «**zéro observation**» associée à la piste 1 et pour la probabilité d’association d’observation numéro 2 à la piste 2.

La probabilité de «**zéro observation**» associée à la piste 1 est : $\mathbf{Prob}_{10} = \text{Prob}(H_1) + \text{Prob}(H_2) + \text{Prob}(H_3) + \text{Prob}(H_4) + \text{Prob}(H_5) + \text{Prob}(H_6) + \text{Prob}(H_7) + \text{Prob}(H_8)$; où $\text{Prob}(H_i)$ sont des probabilités des hypothèses normalisées.

La probabilité d’association d’observation numéro 2 à la piste 2 est :

$$\mathbf{Prob}_{22} = \text{Prob}(H_5) + \text{Prob}(H_6) + \text{Prob}(H_{10}) + \text{Prob}(H_{11}).$$

- étape 8 «**correction des états des pistes qui ont des associations**» : Après les calculs de toutes les probabilités, la phase de correction est appliquée telle qu’elle était décrite plus haut (détails de l’approche JPDA).
- étape 9 «**création des pistes pour les observations qui n’ont pas été associées à des pistes existantes**» : l’étude de la matrice d’association montre que l’observation o_5 n’a été associée à aucune piste déjà existante. Donc, pour celle-ci une nouvelle piste est créée.

IV.3 Résultats expérimentaux

Nous présentons dans ce paragraphe des résultats qualitatifs de l’apport de l’intégration du contexte dans un processus complet de suivi.

Ce paragraphe montre les résultats obtenus en appliquant notre approche sur des données réelles délivrées par un capteur laser à balayage (IBEO). Ces données, acquises avec le logiciel RTMaps, nous ont été fournies par l’Ecole Nationale Supérieure des Mines de Paris.

IV.3.1 Protocole de l’étude

Nous appliquons la méthode de détection (segmentation et modélisation) basée sur les invariants géométriques de la scène que nous avons développé et présenté dans le chapitre III.

Le vecteur d’état de chaque objet est composé des positions (horizontale et verticales) et vitesses (horizontale et verticale). Le périod de l’échantillonnage des acquisitions est de l’ordre de 0.1s. Les observations, provenant de l’étape de détection, considérées dans la phase d’association et de correction du Filtre JPDA sont les centres des modèles établis pour chaque objet.

Il s’agit bien sûr, pour suivre et déterminer les paramètres dynamiques de chacun des objets, d’établir un modèle dynamique de mouvement. Nous utilisons le même modèle que dans le chapitre II. Cependant, nous rappelons ici les grandes lignes de ce modèle cinématique (position/vitesse).

On définit donc le vecteur d’état d’un objet par $X = [x, v_x, y, v_y]^T$ avec x et y les coordonnées de l’objet suivi et v_x et v_y la vitesse en x et en y de l’objet.

Les équations de dynamique s’écrivent :

$$X_t = F_t X_{t-1} + W_{t-1}$$

où $F_t = \begin{pmatrix} 1 & T_e & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & T_e \\ 0 & 0 & 0 & 1 \end{pmatrix}$ est la matrice de transition ; T_e la période d'échantillonnage.

et $W_t = (0 \ \omega_t^x \ 0 \ \omega_t^y)$ est un bruit blanc gaussien de moyenne nulle et de matrice de covariance :

$$Q = \begin{pmatrix} \frac{T_e^3}{3} & \frac{T_e^2}{2} & 0 & 0 \\ \frac{T_e^2}{2} & T_e & 0 & 0 \\ 0 & 0 & \frac{T_e^3}{3} & \frac{T_e^2}{2} \\ 0 & 0 & \frac{T_e^2}{2} & T_e \end{pmatrix} \cdot \sigma^2$$

où σ^2 est la variance des bruits ω_t^x et ω_t^y sur la vitesse (σ de l'ordre de 1,7 m/éch., soit une accélération d'environ 7,8 m/s²)

On modélise les observations par :

$$Z_t = \begin{pmatrix} x_t^{obs} \\ y_t^{obs} \end{pmatrix} = H_t X_t + V_t$$

où $H_t = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix}$ est la matrice d'observation

et V_t est un bruit blanc gaussien de moyenne nulle et de covariance $R = \begin{bmatrix} \sigma_x^2 & \sigma_{xy}^2 \\ \sigma_{yx}^2 & \sigma_y^2 \end{bmatrix}$.

La matrice de covariance du bruit d'observation en coordonnées cartésiennes est calculée en fonction des écarts-types (σ_ρ et σ_θ) des erreurs de mesures en coordonnées polaires par :

$$\sigma_x^2 = \sigma_\rho^2 \cos^2 \theta + \sigma_\theta^2 \rho^2 \sin^2 \theta, \quad \sigma_y^2 = \sigma_\rho^2 \sin^2 \theta + \sigma_\theta^2 \rho^2 \cos^2 \theta,$$

$$\sigma_{xy}^2 = \frac{1}{2} \sin 2\theta [\sigma_\rho^2 - \sigma_\theta^2 \rho^2] \text{ et } \sigma_{yx}^2 = \sigma_{xy}^2.$$

La nature physique du capteur a permis de modéliser σ_ρ et σ_θ constants.

IV.3.2 Evaluation de l'apport du contexte

Nous allons présenter une première évaluation de notre approche en comparant quelques résultats provenant d'un processus de suivi appliquée à des données réelles (données ENSMP acquises avec RTMaps) lorsque la probabilité de détection est définie au préalable, sans prise en compte du contexte et des résultats provenant des mêmes données, mais lorsque le suivi intègre le contexte par l'approche proposée.

Les traitements se déroulent sur une séquence d'une durée d'environ 45s, avec une période d'échantillonnage des mesures égale à 0,1s. On rappelle aussi que la résolution angulaire du capteur

est $\alpha = 0,25^\circ$. L'ouverture angulaire β est comprise entre 10° et 170° . La taille des véhicules n'évolue pas et on suppose ne détecter que des « voitures » dont les dimensions moyennes sont données au paragraphe III.7.2.2. Durant toute la séquence, il y a au maximum deux véhicules dans la scène. Un véhicule, celui sur la gauche du véhicule porteur du capteur, accélère et ralentit, provoquant soit des sorties de champ de vision soit des occultations. Le second véhicule reste toujours à l'avant du capteur, avec une dynamique relativement stable.

Il se produit donc, durant cette séquence, différents événements qui s'apparentent à la notion de contexte, telle que nous l'avons définie jusqu'à présent, ou à des erreurs de détection. Nous illustrons sur la figure 102 quelques-uns des événements qui se produisent dans cette séquence. Chacune de ces acquisitions représente une situation que nous pourrons repérer sur l'évolution des résultats de suivi.

Sur cette figure, nous faisons apparaître les limitations du champ d'observation pour la détection. Ces limites ont été définies *a posteriori*, après visionnage des données. Pour une utilisation *in situ*, il va de soi que ces limites devront être déterminées au fil des détections. Ces limites ne peuvent pas être déterminées avec le seul capteur télémétrique. Il faudra l'apport d'un autre capteur, telle qu'une caméra 2D couplée par exemple, à un algorithme de détection des lignes de signalisation au sol pour localiser la zone d'observation ou bien un capteur de géolocalisation de type GPS.

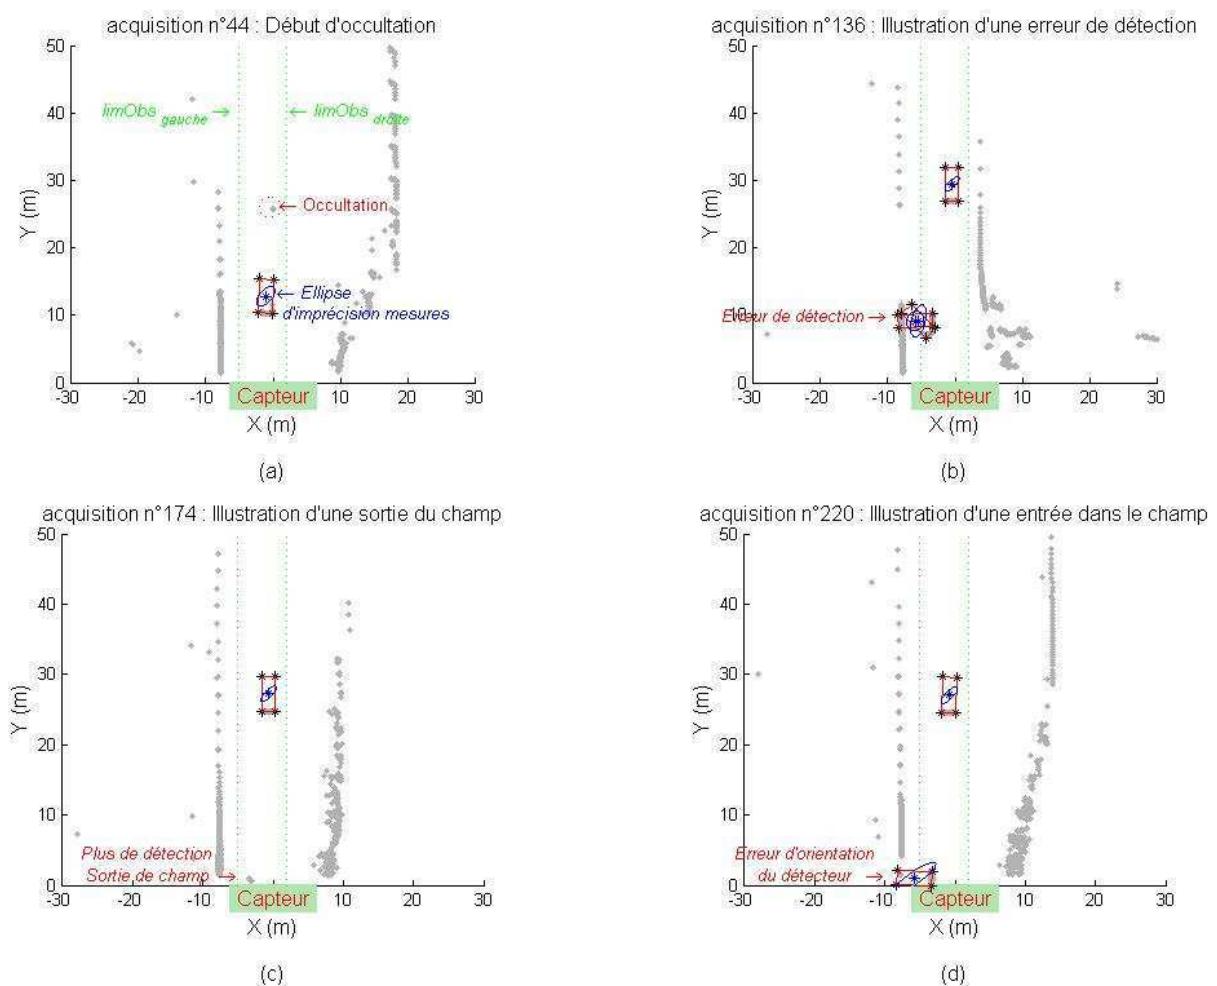


Figure 102 : Illustrations de différentes situations décrivant des modifications du contexte

Sur la partie (a), nous présentons un cas d'occultation d'un objet par un autre (contexte objet/objet). C'est précisément à cet instant d'acquisition que l'objet n'est plus détecté. Le filtre d'estimation va alors entrer en prédiction pure pendant un temps fixé (nous avons choisi 5 acquisitions) avant de terminer cette piste. Sur la partie (b), le détecteur détecte 2 objets (au lieu d'un). Il y aura donc potentiellement deux pistes à suivre. Sur la partie (c), nous illustrons une sortie du champ de vision (la visibilité diminue pour devenir nulle). A noter qu'à l'instant d'acquisition présenté, le véhicule n'est déjà plus détecté. Sur la partie (d), l'objet revient dans la scène. On remarque une erreur forte d'orientation et même si l'orientation des véhicules n'entre pas dans l'estimation, cela engendre une erreur de détection en position. Cette erreur est due à la partie modélisation du détecteur, puisque la taille de la surface détectée est, à cet instant, inférieure à la largeur d'un véhicule.

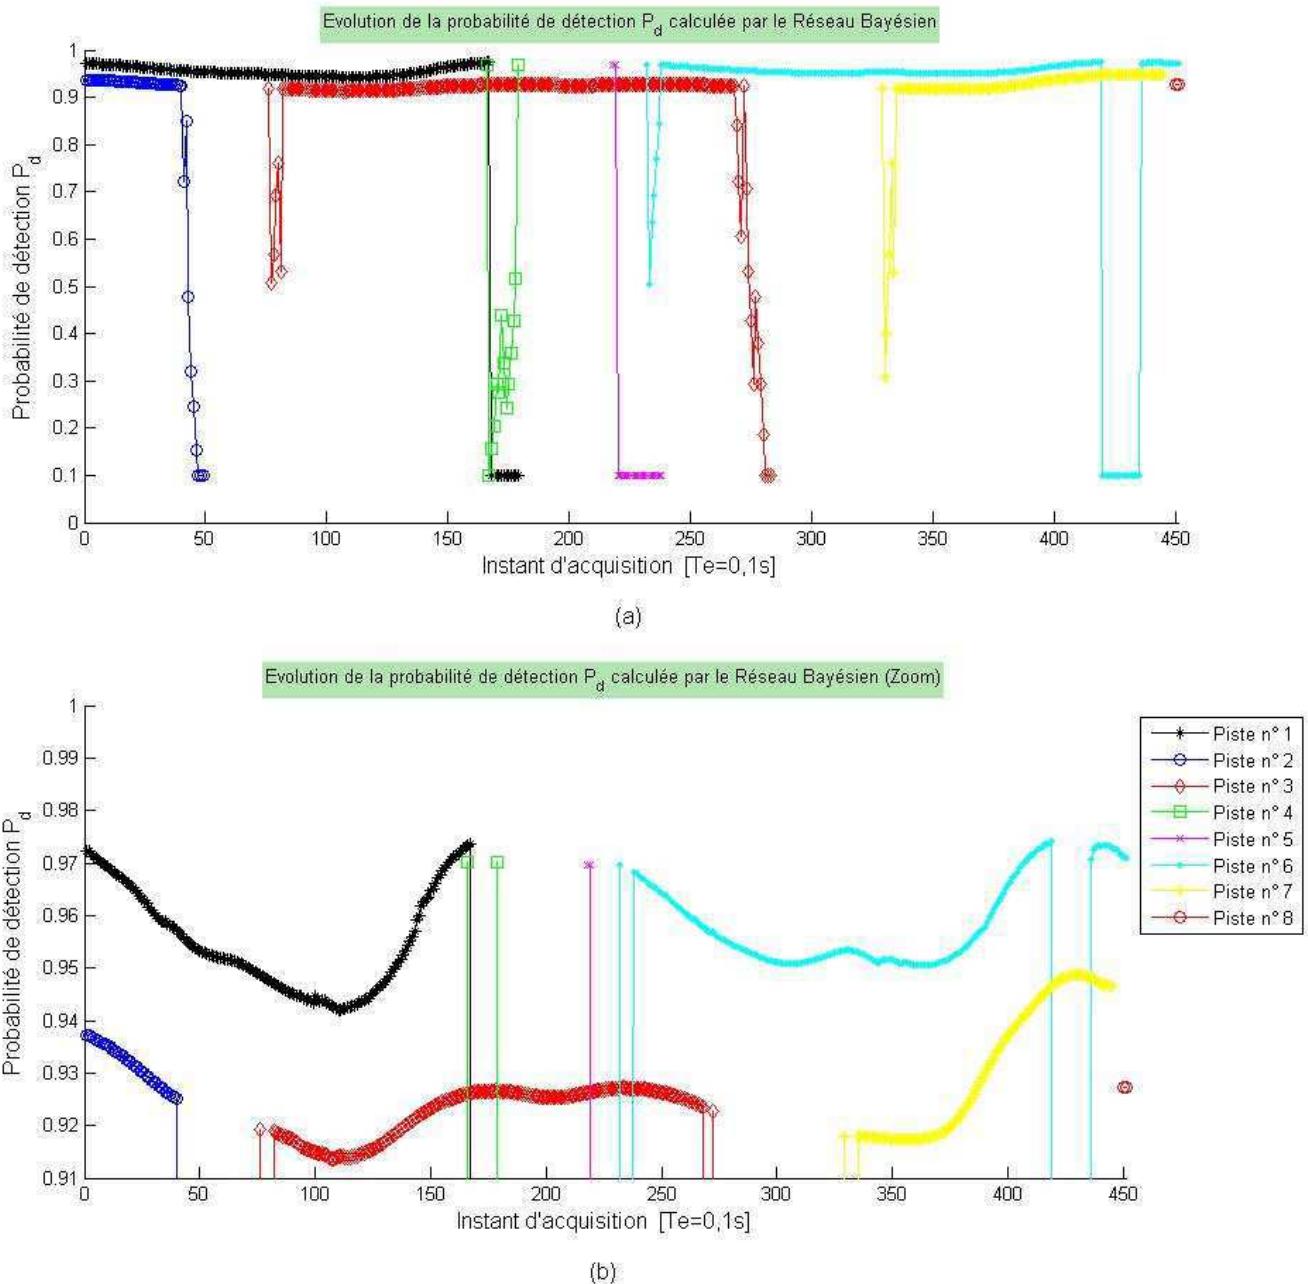


Figure 103 : Evolution de la probabilité de détection P_d pendant toute la séquence.

La figure 103 montre l'évolution de la probabilité de détection P_d estimée, à chaque instant d'acquisition, en intégrant les contextes capteur/objet et objet/objet grâce au réseau bayésien que nous avons présenté plus haut. On peut noter que l'évolution de P_d est relativement faible. On peut l'expliquer par plusieurs raisons, au regard de la caractérisation de l'algorithme de détection présentée dans le paragraphe III.7.2.3. D'abord la résolution du capteur est petite, donc le nombre d'impacts par objet est assez élevé. Ensuite, la taille des véhicules est fixe et donc n'a pas d'influence sur la détectabilité. On voit ici l'intérêt d'une étape de classification des véhicules, qui n'est cependant pas possible avec un unique capteur et qui nécessite encore l'emploi d'une caméra par exemple.

Cependant, la probabilité de détection P_d évolue comme attendu, prenant en compte les distances des objets au capteur, les pertes de visibilité et les occultations. On remarque ici que le choix d'une variable « Occultation » continue serait vraisemblablement profitable pour décrire l'évolution de la probabilité de détection P_d .

La partie (b) de la figure 103 n'est qu'un zoom de la partie (a) de manière à voir correctement les variations.

Nous présentons sur la figure 104, les résultats de l'estimation des positions des véhicules en coordonnées Y. Nous voyons bien les évolutions des deux véhicules de la scène, l'un assez proche du capteur et l'autre plus éloigné. Nous avons également repéré les différents cas, de (a) à (d), que nous avons évoqué sur la figure 102. Il s'agit en fait d'une comparaison de l'estimation en position (selon la coordonnées Y) entre un suivi qui intègre une probabilité variable déterminée par le réseau bayésien, et un suivi pour lequel P_d est fixe. Pour cette première comparaison, nous avons pris une probabilité moyenne ($P_d = 0,95$) à la vue de la courbe d'évolution de la figure 103.

Qualitativement, nous pouvons dire que les deux algorithmes gèrent d'une manière identique les occultations et les sorties de champs de vision (cas (a) et cas (c)). Pour le cas (b), la seconde piste n'est pas associée par notre algorithme, ne créant ainsi pas d'autre piste. Cette fausse détection est en effet considérée comme fortement occultée par le réseau bayésien, qui lui attribue donc une P_d très faible. De cette façon, cette détection n'est pas associée, contrairement à l'autre algorithme, qui d'ailleurs n'estime pas correctement les évolutions de l'objet (pistes n°3 et 4). On retrouve d'ailleurs une autre situation de ce même type pour le même véhicule (autour de l'acquisition 400) dans cette séquence. A l'inverse, lors de l'entrée dans le champ de vision (cas (d)), notre algorithme met un certain temps à accrocher la piste réelle. Cette fois-ci, c'est la partie visibilité du réseau bayésien qui restreint la probabilité de détection entraînant un défaut au niveau du suivi de cet objet. Cependant, dès que l'objet est suffisamment visible, l'estimation devient correcte.

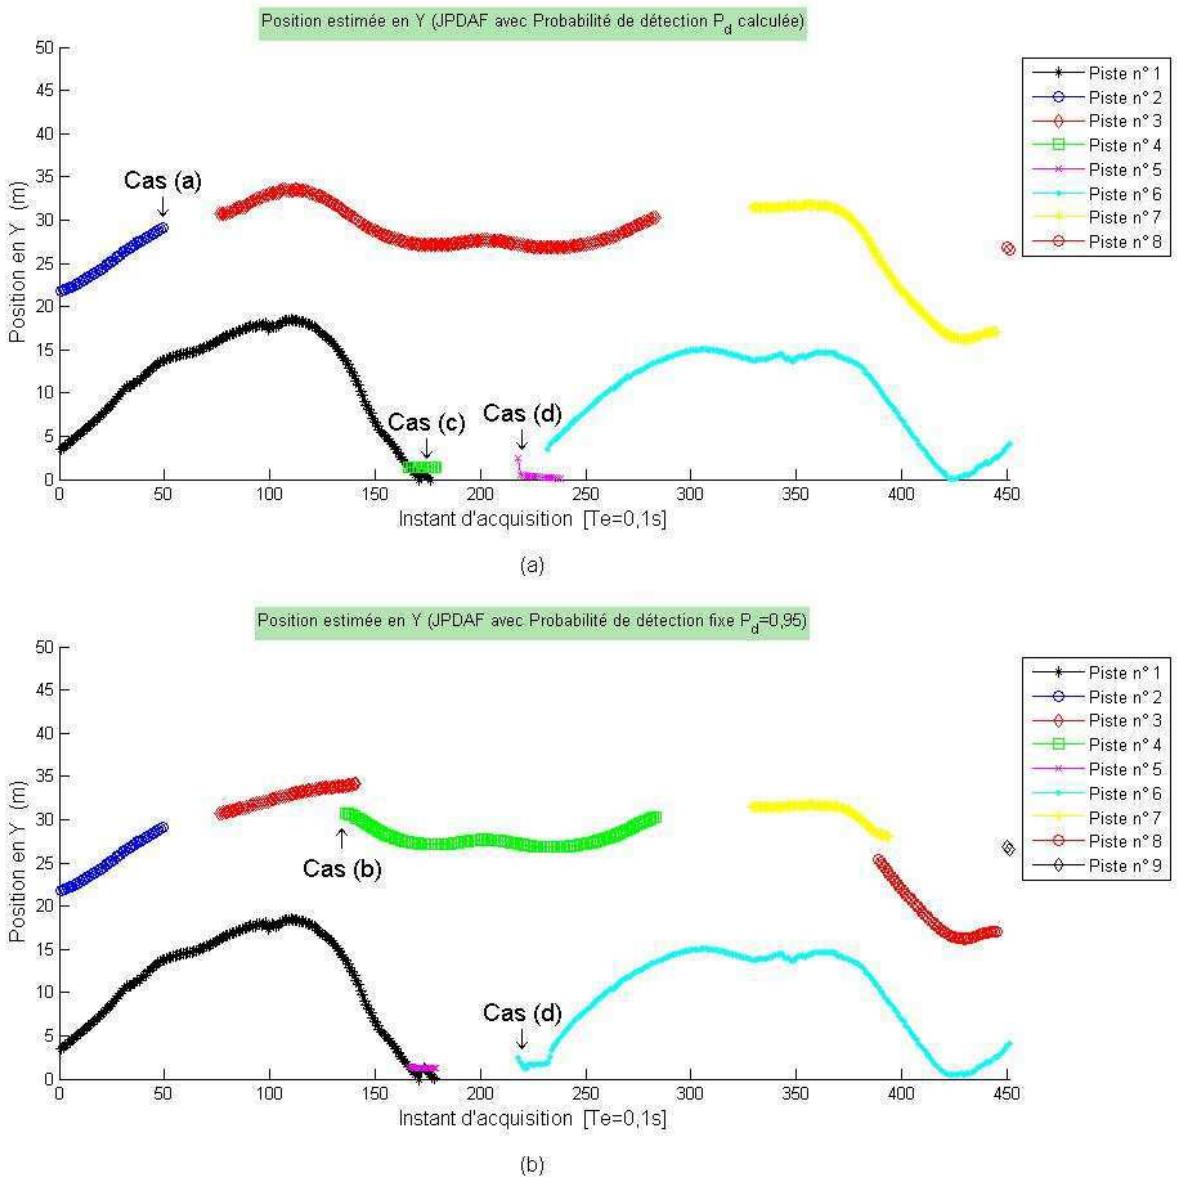


Figure 104 : Comparaison des positions estimées en Y pour un suivi avec P_d calculée et un suivi avec P_d fixe ($P_d = 0,95$).

Nous présentons sur la figure 105, les mêmes résultats pour deux algorithmes de suivi avec P_d fixe ($P_d = 0,99$ et $P_d = 0,5$), c'est-à-dire une évaluation optimiste de la probabilité de détection et une évaluation pessimiste de cette même probabilité.

On voit très vite l'effet négatif sur le suivi d'une détermination pessimiste de la probabilité de détection : création de pistes, mauvaises estimations avec un phénomène de mauvaises mises à jour de l'état estimé. Par contre, une surévaluation de P_d , semble donner de meilleurs résultats. Cependant, si l'on regarde d'un peu plus près, les estimations du véhicule le plus éloigné sont sensiblement meilleures avec notre algorithme en retour d'occultation (après le cas (a)). De plus, il faudrait mettre les deux algorithmes en concurrence pour plus de situations et dans des cas plus limites pour conclure définitivement. C'est aussi, sans doute, une conséquence de la bonne qualité du détecteur sur ce type de données. Il faudrait, en particulier, voir le comportement des deux

algorithmes lorsque la résolution angulaire diminue et que le nombre de fausses alarmes augmente, car c'est dans ce cas qu'un comportement optimiste peut entraîner de mauvais comportement en estimation.

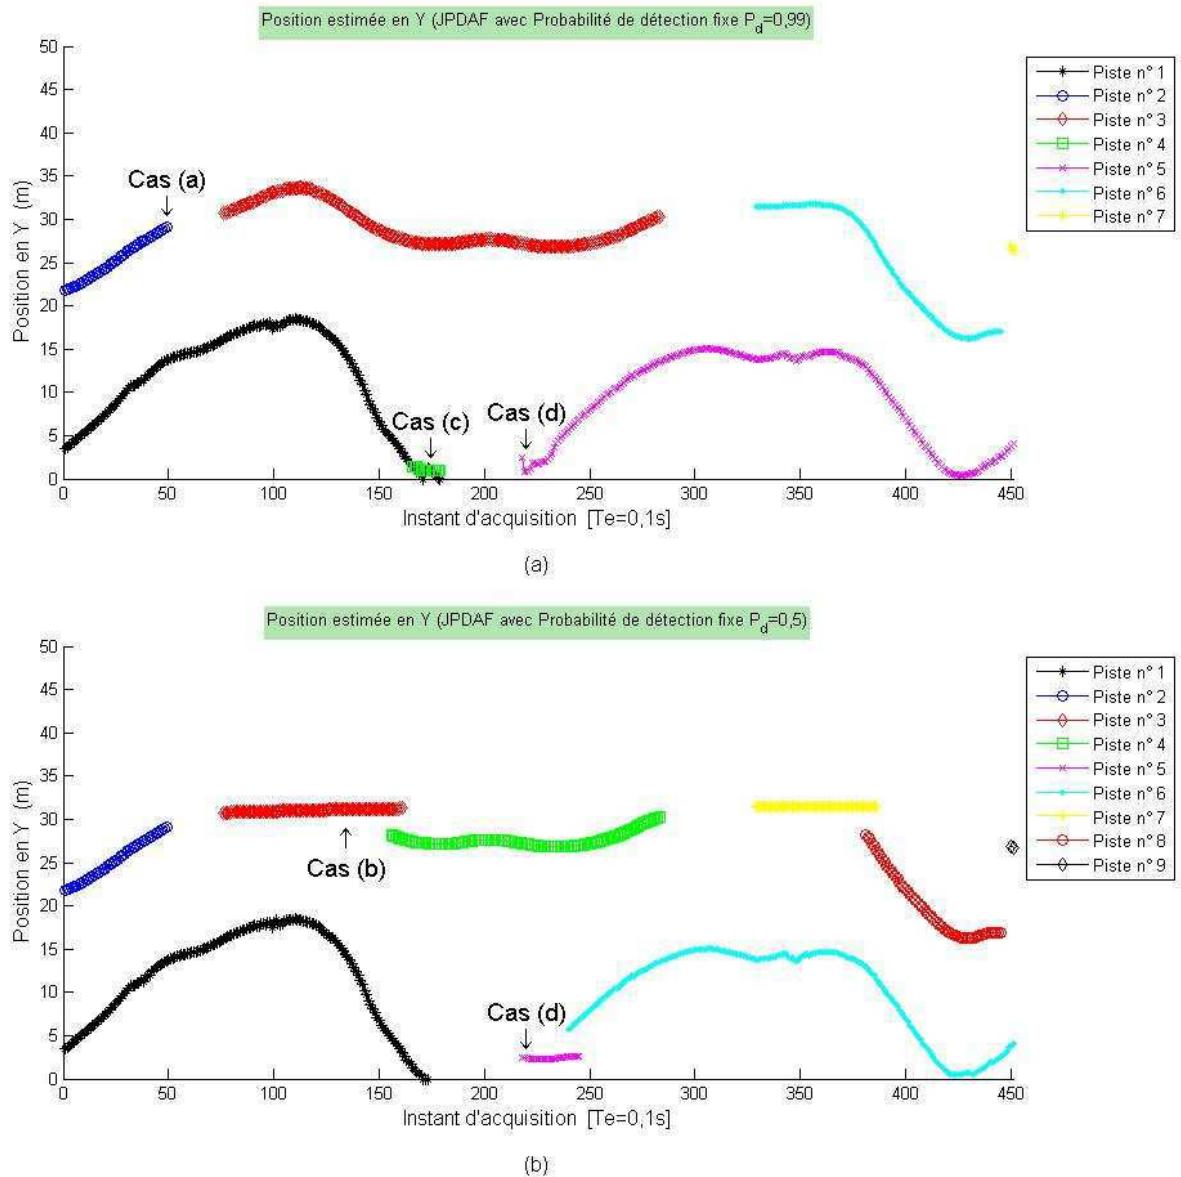


Figure 105 : Comparaison des positions estimées en Y avec $P_d = 0,99$ et $P_d = 0,5$.

La figure 106 propose les résultats des algorithmes précédents (avec les différentes valeurs de la probabilité de détection évoquées). On ne voit pas ou peu de différences pour ces résultats, sauf bien sûr une mauvaise estimation lorsque la probabilité de détection est trop faible.

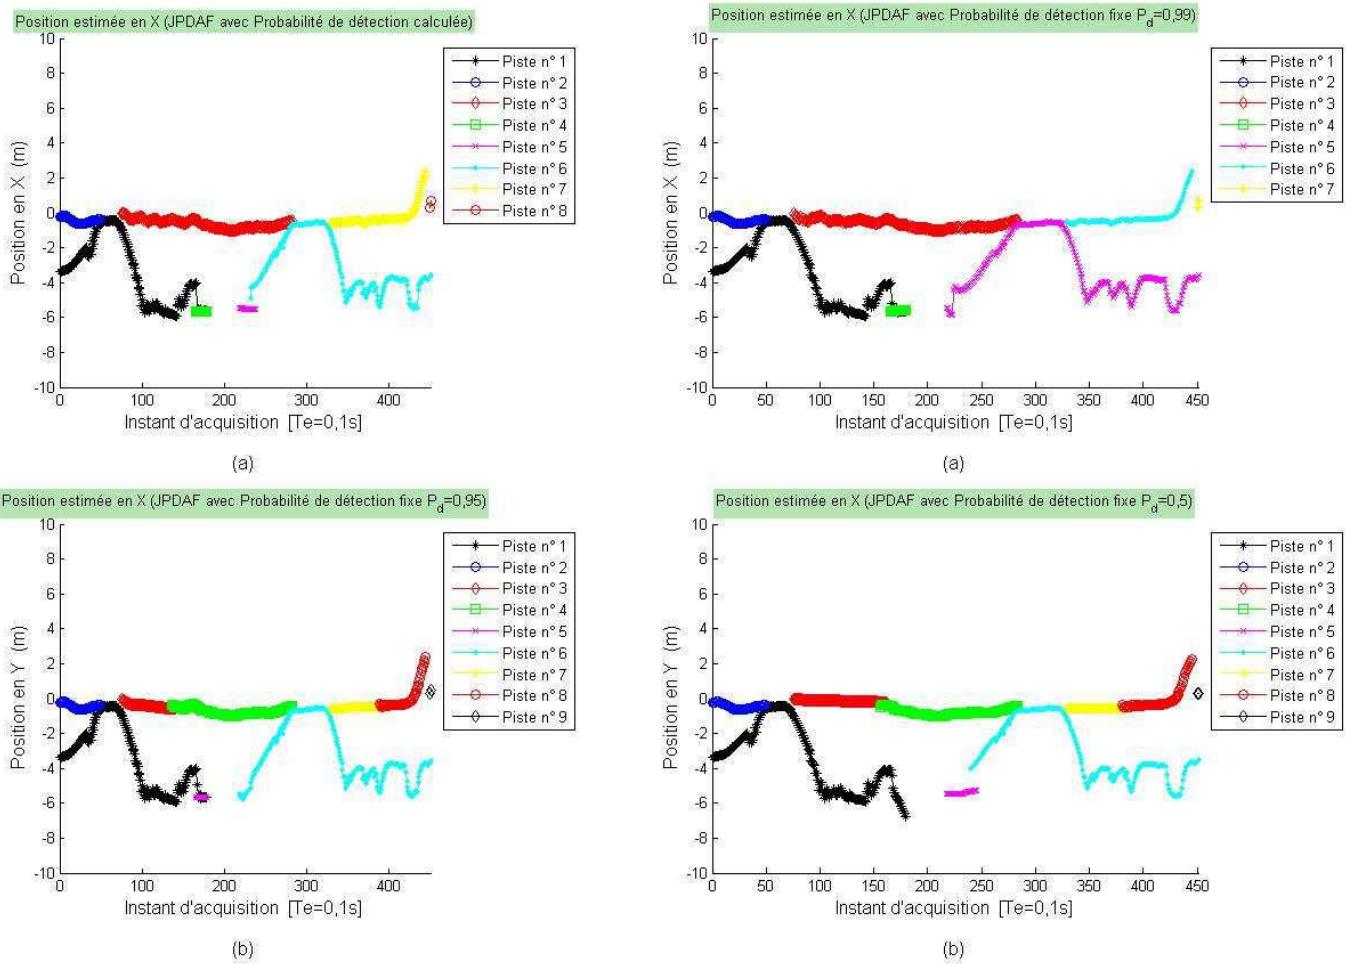


Figure 106 : Comparaison des positions estimées en X pour différentes P_d

Pour terminer l'évaluation de notre approche, nous allons donner les résultats de l'estimation en vitesse (latérale et longitudinale), en la comparant avec un algorithme de suivi utilisant une probabilité de détection fixe ($P_d = 0,95$). Ces comparaisons se trouvent sur les figures suivantes (figure 107 et figure 108). Il s'agit évidemment de vitesses relatives, la vitesse du véhicule porteur étant supposée constante (ou alors connue par une utilisation d'autres capteurs).

Pour l'estimation de la vitesse longitudinale, on observe bien un ralentissement assez brutal pour l'un des véhicules (piste n°1) avant de sortir du champ de vision. On retrouve, encore une fois, un meilleur comportement en estimation pour notre approche intégrant le contexte, par exemple au regard de l'estimation de la vitesse du véhicule représenté par la piste n°3.

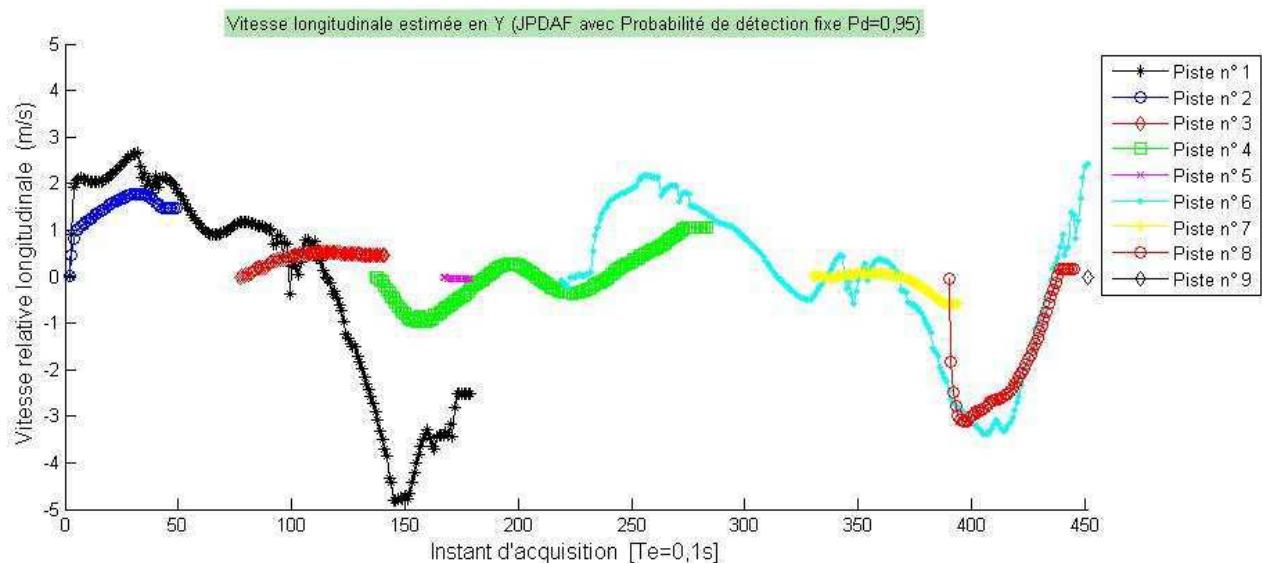
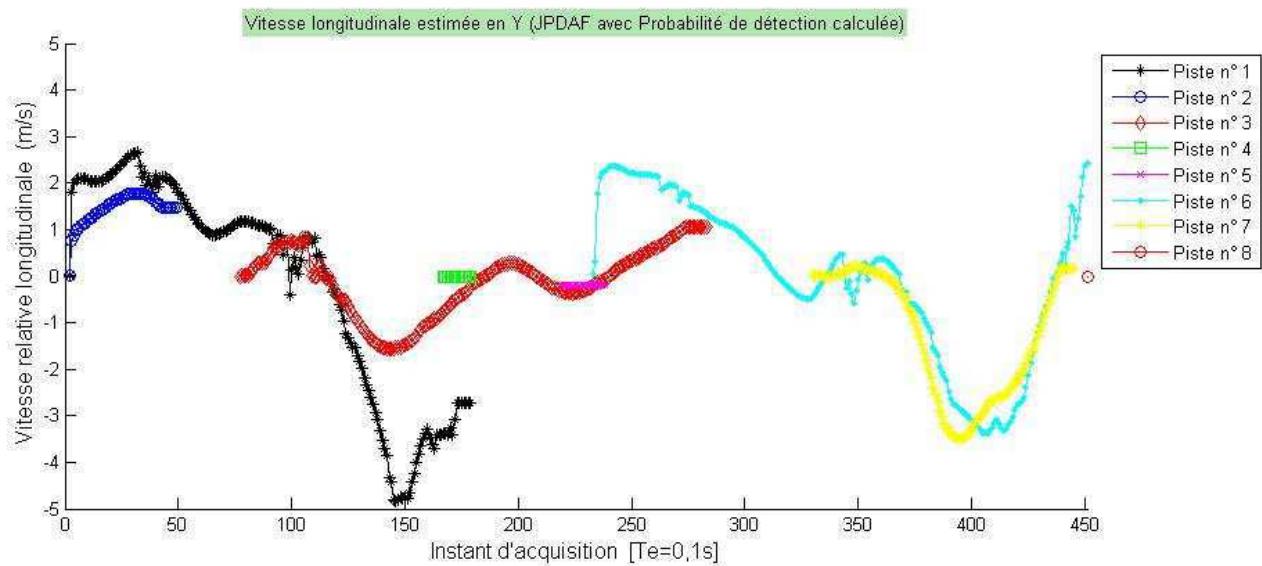


Figure 107 : Comparaison des vitesses longitudinales relatives estimées pour un suivi avec P_d calculée et un suivi avec P_d fixe ($P_d = 0,95$).

Pour les vitesses latérales, l'estimation est sensiblement la même pour les deux approches, même si on peut noter une meilleure sensibilité aux variations pour notre approche pour certaines pistes (piste n°3, par exemple). Il est cependant difficile de juger les performances pour les vitesses sans avoir une connaissance des vitesses des véhicules présents. Par exemple, lorsque l'on regarde d'un peu plus près, on s'aperçoit que les variations fortes de la piste n°1 sont en fait dues aux erreurs en orientation du détecteur, entraînant des mouvements parasites pour les objets.

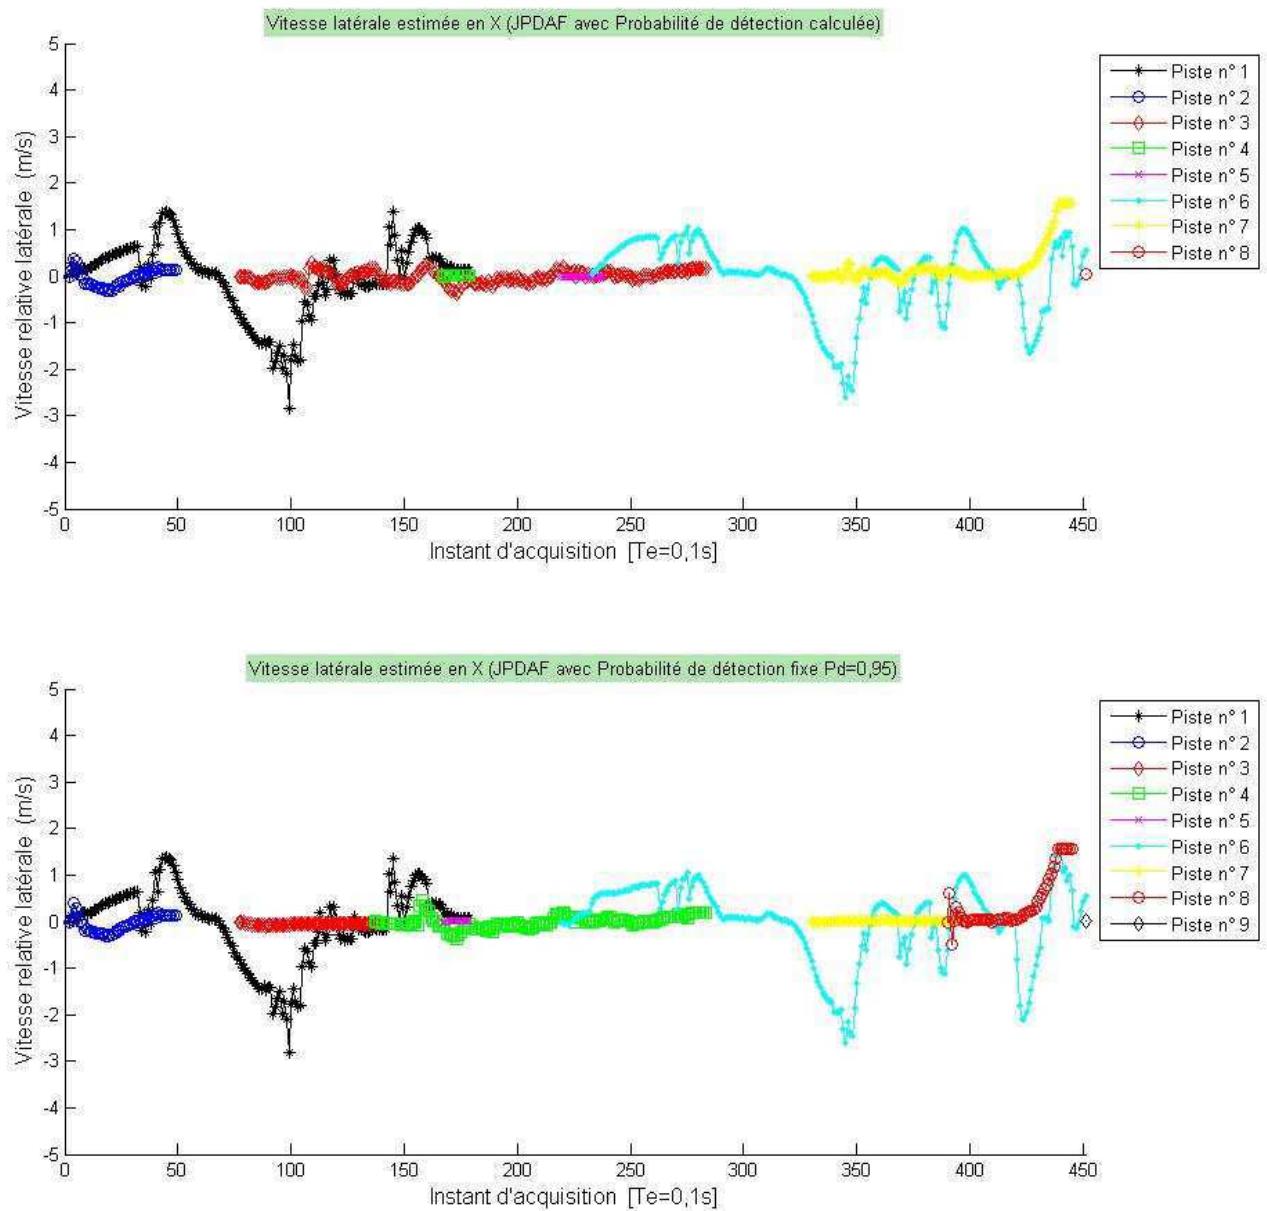


Figure 108 : Comparaison des vitesses latérales relatives estimées pour un suivi avec P_d calculée et un suivi avec P_d fixe ($P_d = 0,95$).

IV.4 Conclusion

Nous avons présenté dans ce chapitre l'intégration du contexte dans son ensemble (capteur/objet et objet/objet) dans un processus de suivi utilisant une approche JPDA. Après avoir présenté la modélisation proposée pour intégrer le contexte par les réseaux bayésiens et avoir rappelé l'approche JPDA avec ses différents points clés, nous avons présenté des résultats qualitatifs afin de montrer la pertinence des choix effectués, mais aussi de valider la nécessité de déterminer de

manière dynamique la probabilité de détection pour chacun des objets suivis. Les premiers résultats sont très encourageants et vont dans le sens d'une amélioration du suivi. Certes, il est maintenant nécessaire, pour valider définitivement l'approche, de comparer les résultats sur des données synthétiques en mettant à l'épreuve l'algorithme dans des situations extrêmes et sur un ensemble plus grand de scénarios réels. Comme on l'imagine, ce sera également le moyen de montrer que l'approche par détermination dynamique de P_d est dans tous les cas, et même comparée à une surévaluation optimiste de P_d , meilleure.

De plus, pour le réseau bayésien, il devient indispensable d'intégrer certaines variables sous forme continue (on pense à l'occultation et à la visibilité). Cependant, une phase d'apprentissage afin de déterminer les tables des probabilités conditionnelles, qui deviendront des fonctions pour les variables continues, sera nécessaire afin de lever les heuristiques utilisées dans ce travail, même si elles proviennent avant tout du bon sens.

Conclusion et perspectives

Nous avons présenté dans ce manuscrit une contribution à la détection et au suivi d'objets multiples à partir de données télémétriques. L'objectif est à terme d'envisager l'approche proposée dans un système complet d'assistance au conducteur en termes d'amélioration de sa sécurité.

Parmi l'ensemble des problèmes envisageables pour un tel objectif, nous nous sommes focalisés sur deux étapes clés du processus complet de détection/estimation. La première concerne l'étape de détection qui est centrale car elle conditionne directement les performances de l'ensemble de la chaîne de traitement.

Nous avons donc développé une méthode de détection qui exploite certains invariants géométriques, caractéristiques de l'application étudiée. Cette méthode s'est notamment attachée à éviter toute transformation entre les mesures naturellement polaires et le système de coordonnées cartésiennes du repère de la scène. Cette démarche ayant été faite dans le souci de préserver l'optimalité des traitements mais aussi de respecter la statistique des bruits de mesure. Nous avons en particulier comparé les performances de l'approche proposée avec les méthodes usuelles sur ce type de données.

Le deuxième point original de cette thèse concerne l'intégration du contexte dans le processus d'association-estimation. En effet, dans le formalisme général de l'association probabiliste de données, les probabilités de détection et de fausse alarme occupent une place centrale. Dans le cas de données télémétriques, l'influence du contexte sur la probabilité de détection est loin d'être négligeable. Il agit en effet à deux niveaux :

- contexte capteur/objet ;
- contexte objet/objet.

En résumé, dans l'étape d'association, la probabilité de détection ne peut en aucune manière être considérée constante, comme cela est très souvent le cas en pratique. Nous avons donc proposé une méthode basée sur les réseaux bayésiens qui permet d'évaluer de manière dynamique la probabilité de détection de chaque objet. Cette évaluation peut alors servir de base aux méthodes PDA et JPDA exploitées dans ce manuscrit.

Concernant la probabilité de fausse alarme, elle apparaît essentiellement dépendante du détecteur mis en œuvre. Au regard de la complexité générale des méthodes de détection sur données télémétriques qui rend très difficile toute approche analytique, nous avons évalué expérimentalement de manière exhaustive les performances du détecteur en termes de fausses alarmes. Ceci permet d'en obtenir une évaluation différente suivant le cas d'étude.

Ces approches ont finalement été appliquées sur données synthétiques radar et réelles lidar (SICK LMS200, IBEO) afin de les valider en situation.

Les travaux développés dans ce mémoire ouvrent de nombreuses perspectives :

- au niveau contextuel : on peut tout d'abord envisager d'étendre la prise en compte du contexte à un ensemble de paramètres plus vaste (conditions climatiques qui modifient le comportement des capteurs, cartographie ...).
- modèles dynamiques : nous avons travaillé ici avec des modèles cinématiques simples mais suffisants dans de nombreux cas. On peut également envisager d'exploiter plusieurs modèles dynamiques suivant le contexte expérimental.
- modèles géométriques : l'extension au cas de modèles géométriques de formes différentes peut également être couplée à la prise en compte de modèles dynamiques variés.
- capteurs : l'amélioration des performances en détection et suivi peuvent être grandement améliorées par l'exploitation de données issues de capteurs différents, caméra notamment, dans un système complet de perception multicapteurs. Cette approche permet également d'aider au processus de classification/modélisation des objets détectés.

Annexe A : Présentation des réseaux bayésiens

Les réseaux bayésiens sont apparus à la fin des années 70. Ils sont venus, au milieu des années 80 [Pearl, 1986], compléter les technologies des systèmes experts par leur capacité de coordonner des inférences bidirectionnelles et se sont imposés comme un schéma de représentation général de la connaissance incertaine.

Les réseaux bayésiens sont les résultats d'une convergence entre, d'une part les méthodes statistiques qui sont précisément conçues pour permettre le passage de l'observation à la loi de probabilité et, d'autre part, les technologies de l'intelligence artificielle dont l'objectif est de permettre aux ordinateurs de traiter de la connaissance plutôt que de l'information. Ils constituent l'un des formalismes le plus complet et le plus cohérents pour l'acquisition, la représentation et l'utilisation de connaissances par des ordinateurs. Ils sont devenus couramment utilisés dans le domaine de la recherche (contrôle de véhicule autonome, data mining, etc.) au début des années 90.

A.1 : Définition des réseaux bayésiens

Un réseau bayésien repose sur la théorie des graphes et sur les distributions de probabilités. C'est un modèle de représentation de la connaissance qui permet le calcul de probabilités conditionnelles par inférence. La théorie des graphes est utilisée pour représenter les dépendances conditionnelles ou causales des entités (variables ou noeuds) du système étudié. Les distributions de probabilités définissent mathématiquement ces dépendances conditionnelles entre les noeuds du système. Elles servent au calcul de la probabilité d'un « noeud fils » à partir des probabilités des « noeuds parents ».

Représentation graphique

La représentation des réseaux bayésiens se fait par un graphe (causal) acyclique dirigé composé de noeuds et d'arcs. Les noeuds représentent les variables du système (figure 109). Chaque arc spécifie les dépendances causales entre deux noeuds : la relation de cause à effet entre ces noeuds est représentée par une flèche dirigée (arc) partant d'un noeud parent vers un noeud fils.

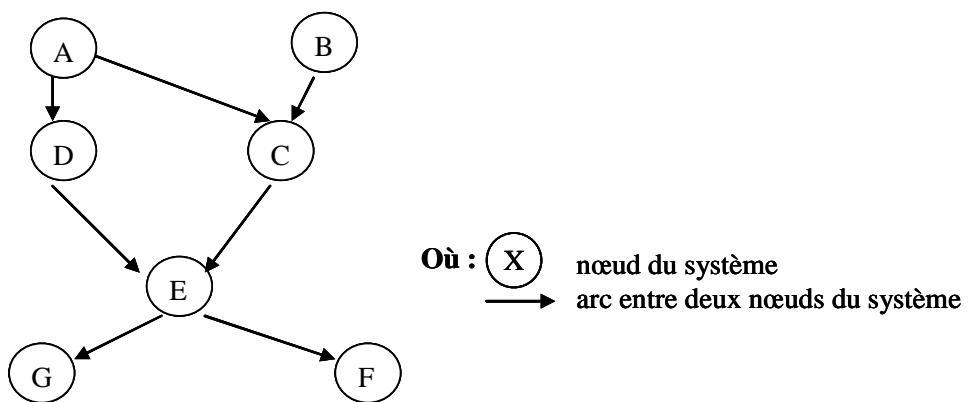


Figure 109 : illustration d'un graphe causal

Dans la figure 109, le nœud A est appelé « nœud parent » de D et C, D le parent de E et E le parent de G et F. Inversement, D est le « nœud fils » de A, C le fils de A et B, E celui de D et C et ainsi de suite. Les nœuds racines de ce graphe causal sont les nœuds A et B.

Il existe différents graphes causaux : les graphes causaux à connexion série, à connexion convergente et à connexion divergente (figure 110) :

- *Graphe causal à connexion série* : sur le graphe à connexion série illustré figure 110, la variable F a une influence (i.e. une relation de cause à effet) sur la variable J qui a alors une influence sur la variable K. Par conséquent, l'évidence sur la variable F affectera la certitude sur la variable J qui affectera à son tour la certitude sur la variable K.
- *Graphe causal à connexion divergente* : sur le graphe à connexion divergente illustré figure 110, la variable A a une influence sur tous ses fils (B, C et F) sauf si l'état de la variable A est donné. En effet, si cet état est connu, les variables B, C et F deviennent indépendantes les unes des autres.
- *Graphe causal à connexion convergente* : si l'état de la variable Y du graphe à connexion convergente n'est connu qu'à partir de la connaissance de ses parents C, K et X, alors les parents sont indépendants. L'indépendance signifie que l'évidence sur un des parents n'a aucun effet sur la certitude des autres (les « évidences » d'un graphe sont les nouvelles informations en entrée des nœuds racines qui sont à l'origine de la mise à jour des probabilités des nœuds du réseau bayésien). L'évidence ici peut être une évidence directe sur la variable Y ou bien une évidence d'un de ses fils. Dans les réseaux causaux, ce fait s'appelle la dépendance conditionnelle.

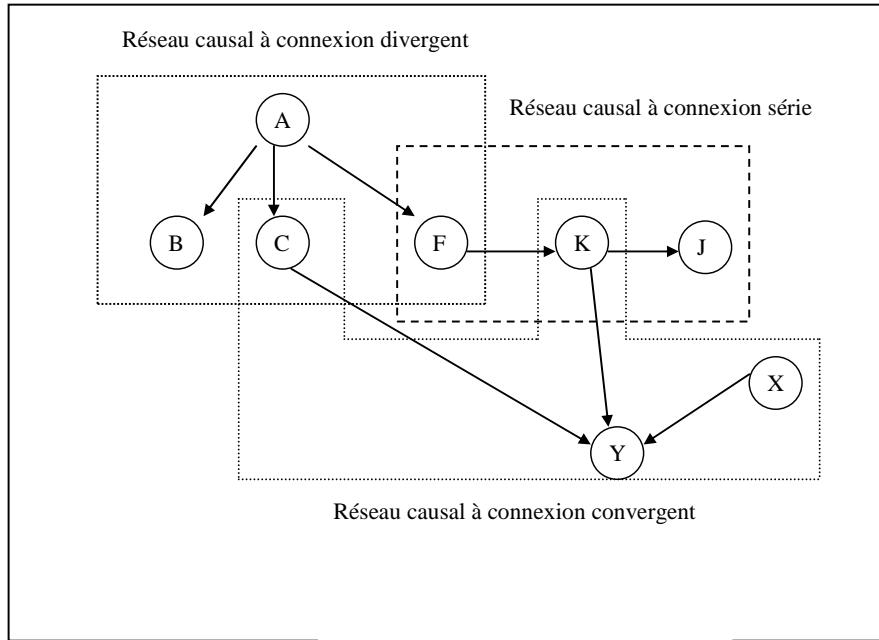


Figure 110 : Connexion divergente, convergente et série d'un réseau bayésien

Tout graphe causal d'un réseau bayésien modélisant un système est construit à partir de ces trois types de réseaux causaux qui servent à représenter les relations entre les variables du système.

Représentation probabiliste

A chaque nœud du réseau bayésien est attachée une probabilité d'occurrence de l'état X du nœud. Une distribution de probabilité est affectée à chaque arc qui est fonction de l'état du nœud parents et du nœud fils. On appelle ainsi :

- probabilité conditionnelle la distribution de probabilité affectée à chaque arc qui est fonction de l'état du nœud parents et du nœud fils,
- probabilité a priori, la probabilité des nœuds racines du réseau bayésien (nœuds A et B dans notre figure 109) calculée selon la connaissance a priori de l'évolution du système,
- probabilité a posteriori, la probabilité d'un nœud fils induite par inférence des probabilités des nœuds parents à l'aide des distributions de probabilité des arcs.

« L'inférence » est la propagation de l'information d'une variable au sein du réseau après une observation de l'état des autres variables. L'inférence dans les réseaux bayésiens permet de prendre en compte n'importe quel état d'une variable d'observation (un événement) ainsi que d'effectuer la mise à jour des probabilités des autres variables. C'est donc le calcul de probabilités des variables non observées en fonction des valeurs des variables observées [Stephenson, 2000].

Définition formelle des réseaux bayésiens

[Becker, 1999], [Naim, 2004] et [Corméjols, 2002] donnent la définition formelle suivante d'un réseau bayésien. Un réseau bayésien est :

- un graphe dirigé sans cycle G , $G=(X, A)$ où X est l'ensemble des nœuds de G et A l'ensemble des arcs de G ;
- un espace probabilisé fini (Ω, P) ;
- un ensemble de variables aléatoires associées aux nœuds (X_1, X_2, \dots, X_n) du graphe et définies sur $[\Omega, P]$ tel que : $P(X_1, X_2, \dots, X_n) = \prod_{i=1, \dots, n} P(X_i | Pa(X_i))$, où $Pa(X_i)$ est l'ensemble des parents de X_i dans le graphe.

Rappels sur la théorie des Probabilités

Dans ce paragraphe nous rappelons les définitions mathématiques de la théorie des probabilités nécessaires aux calculs des distributions a posteriori à partir de probabilités conditionnelles et *a priori*.

- Théorie des probabilités

Elle repose sur les trois axiomes suivants :

Soit A et B deux événements, $P(A)$ et $P(B)$ leur probabilité respective d'occurrence,

Axiome 1 : $0 \leq P(A) \leq 1$;

Axiome 2 : $P(A)=1$ si et seulement si A est certain

Axiome 3 : si A et B sont mutuellement exclusifs, alors $P(A \vee B) = P(A) + P(B)$.

- Approche probabilistes

Il existe trois approches probabilistes selon [Becker, 1999] :

- dans l'approche fréquentiste, la probabilité fréquentiste prend en compte la fréquence des événements, c'est-à-dire le nombre des événements réalisés sur le nombre total des événements.
- l'approche objectiviste considère que la probabilité est une propriété des objets du monde réel et qu'elle mesure leur propension à avoir tel ou tel comportement.
- l'approche subjectiviste considère que la probabilité mesure la croyance d'un individu en l'occurrence d'un fait donné. Elle n'exige pas que les probabilités soient basées sur des résultats provenant d'expériences répétées, mais celles-ci peuvent être simplement des évaluations subjectives de la certitude d'un événement. Les probabilités subjectives s'appellent également probabilités bayésiennes ou probabilités personnelles [Heckerman, 1995].

C'est l'approche subjectiviste de croyance qui est considérés dans les modèles de causalités des réseaux bayésiens. C'est par contre l'approche fréquentiste qu'utilisent ces réseaux pour une application d'apprentissage.

- dépendance et indépendance conditionnelle

- on parle de dépendance conditionnelle entre deux événements lorsque la probabilité d'un événement dépend d'un autre événement. Par exemple (figure 109), la dépendance de D et A s'écrit $P(D|A)$. $P(D|A)$ est appelée probabilité conditionnelle. La dépendance conditionnelle d'au moins deux événements se calcule à l'aide de la formule de la **probabilité conjointe (ou jointe)**. Pour deux événements A et B, elle s'écrit :

$$P(A \text{ et } B) = P(B|A)P(A) = P(A|B)P(B)$$

Par exemple, la probabilité jointe $P(A,B,C,D,E,F,G)$ des nœuds de la figure 108 est : $P(A).P(B|A).P(C|A,B).P(D|A,B,C).P(E|A,B,C,D).P(F|A,B,C,D,E).P(G|A,B,C,D,E,F)$

- on parle d'indépendance conditionnelle lorsque la probabilité d'un événement ne dépend pas d'un autre événement. Figure 109, la probabilité d'indépendance conditionnelle de A et B s'écrit $P(D|A) = P(D|A, B)$. Dans ce cas, la probabilité conjointe devient $P(A \text{ et } B) = P(A) \times P(B)$.

- Probabilité marginale (ou *a priori*)

Son calcul prend en compte l'entièreté du graphe : les probabilités conditionnelles, la structure du réseau et la distribution jointe des probabilités. La probabilité marginale est la distribution individuelle d'une variable aléatoire qui ne tient pas compte des variations « simultanées » des autres variables aléatoires du système [Becker, 1999], [Naim, 2004].

Soit deux variables aléatoires A et B ayant chacune plusieurs états a_i et b_j , la probabilité $P(a_i)$ s'écrit :

$$P(a_i) = \sum_{j=1}^m P(a_i, b_j). \quad (1)$$

où $P(a_i, b_j)$ est la table des probabilités jointes des états de A et B dont la taille est (n, m) .

La probabilité marginale s'écrit également de façon plus générique ainsi :

$$P(A) = \sum_B P(A, B). \quad (2)$$

- Théorème de Bayes

Il énonce des probabilités conditionnelles. Très largement utilisé ([Becker, 1999], [Stephenson, 2000], [Corméjols, 2002]), il dit que la probabilité *a posteriori* d'une hypothèse est proportionnelle au produit de la probabilité *a priori* par la vraisemblance de l'hypothèse. La vraisemblance de l'hypothèse est la probabilité d'un événement sachant que l'hypothèse est vraie.

Soit A et B deux *variables*, le théorème de Bayes détermine la probabilité de A *sachant* B à partir de la connaissance des probabilités de A, de B et de B *sachant que* A est connue. Il s'écrit :

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)} \quad (3)$$

où P(A) et P(B) sont les *probabilités a priori* (ou marginales) de A et B. Elle est « antérieure » au sens qu'elle précède toute information sur B. P(A|B) est appelée la *probabilité a posteriori* de A sachant B. Elle est « postérieure », au sens qu'elle dépend directement de B. Enfin, P(B|A), pour un B connu, est appelé la *fonction de vraisemblance* de A.

- Table de probabilités

Une table de probabilités décrit les liens entre les nœuds, elle mesure la quantité d'informations qui passent dans le graphe du réseau bayésien à partir des nœuds racines.

On distingue deux types de tables : les tables de probabilités conditionnelles et les tables de probabilités *a priori* (figure 111).

Les tables de probabilités conditionnelles décrivent les relations causales entre les variables du graphe. Leur taille dépend du nombre d'états des nœuds parents et de la variable courante.

Une table de probabilités *a priori* décrit les états d'un nœud du graphe. Les valeurs de ces tables sont recalculées pour chaque nouvelle observation en provenance des racines du graphe. Cette mise à jour des tables de probabilité *a priori* des nœuds fils se fait par inférence suite à la modification de celles des nœuds parents. Des méthodes de mise à jour des tables de probabilité se trouvent dans [Becker, 1999], [Corméjols, 2002].

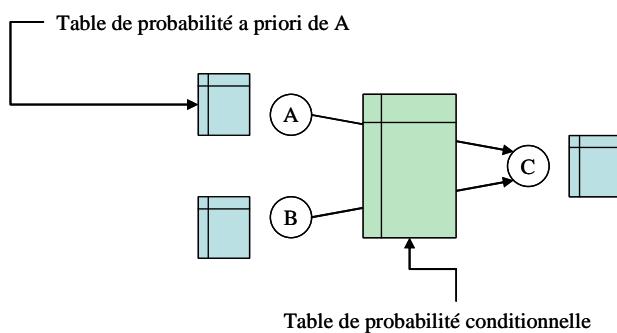


Figure 111 : Tables de probabilité *a priori* et conditionnelles

Circulation d'information dans un réseau bayésien (*d-séparation* de variables)

Figure 110, on dit que A et Y sont *d-séparés* par C ([Naim, 2004], [Corméjols, 2002]) si, pour tout chemin entre les variables A et Y, l'une au moins des deux conditions suivantes est vérifiée :

- « le chemin converge en un nœud X tel que $X \neq C$ et X n'est pas une cause directe de C.
- le chemin passe par C et est soit divergent, soit en série au nœud C » [Naim, 2004].

Si C est la seule information connue dans le chemin, alors C bloque le passage de l'information de A vers Y.

La connaissance des entités *d-séparés* informe des conditions de circulation d'une information à travers le graphe. Elle indique ainsi de la possibilité de révision des probabilités de l'ensemble des autres nœuds du graphe après occurrence d'une nouvelle information [Becker, 1999].

Les calculs de probabilités dans un graphe causal sont rendus locaux si la combinaison avec un autre résultat établit qu'un noeud est *d-séparé* du reste du graphe par l'ensemble constitué de ses parents, de ses fils et des autres parents avec ses fils.

A.2 : Technique de manipulation des réseaux bayésiens

Méthodes de propagation de probabilité dans un réseau bayésien : méthode de Pearl

La méthode de Pearl est une technique de propagation de messages (ou croyances) dans un réseau bayésien [Pearl, 1986]. Elle sert à mettre à jour la probabilité de chaque nœud du réseau après l'acquisition de nouvelles observations (évidences). C'est une technique d'inférence qui est applicable à n'importe quelle structure de réseau bayésien.

Soit un ensemble η comprenant tous les nœuds du réseau. Divisons cet ensemble en deux parties à partir d'un nœud particulier X, η_X^+ est la partie supérieure de cet ensemble, η_X^- la partie inférieure (figure 112).

Supposons que X est incluent dans l'ensemble η_X^- . L'impact des variables observées sur la croyance X peut alors être représenté en utilisant les deux valeurs suivantes :

$$\lambda(X) = P(\eta_X^- | X) \quad (\text{message du fils X vers ses parents } \eta_X^-) \quad (4)$$

$$\pi(X) = P(X | \eta_X^+) \quad (\text{message des parents } \eta_X^+ \text{ vers leur fils X}) \quad (5)$$

X étant un vecteur de valeurs discrètes, $\lambda(X)$ et $\pi(X)$ sont deux vecteurs dont les éléments sont associés à chacune des valeurs de X :

$$\lambda(X) = [\lambda(X = x_1), \lambda(X = x_2), \dots, \lambda(X = x_n)] \quad (6)$$

$$\pi(X) = [\pi(X = x_1), \pi(X = x_2), \dots, \pi(X = x_n)] \quad (7)$$

Etant donné (4) et (5), la probabilité postérieure de X sachant η s'écrit :

$$P(X | \eta) = \beta \cdot \lambda(X) \cdot \pi(X) \quad (8)$$

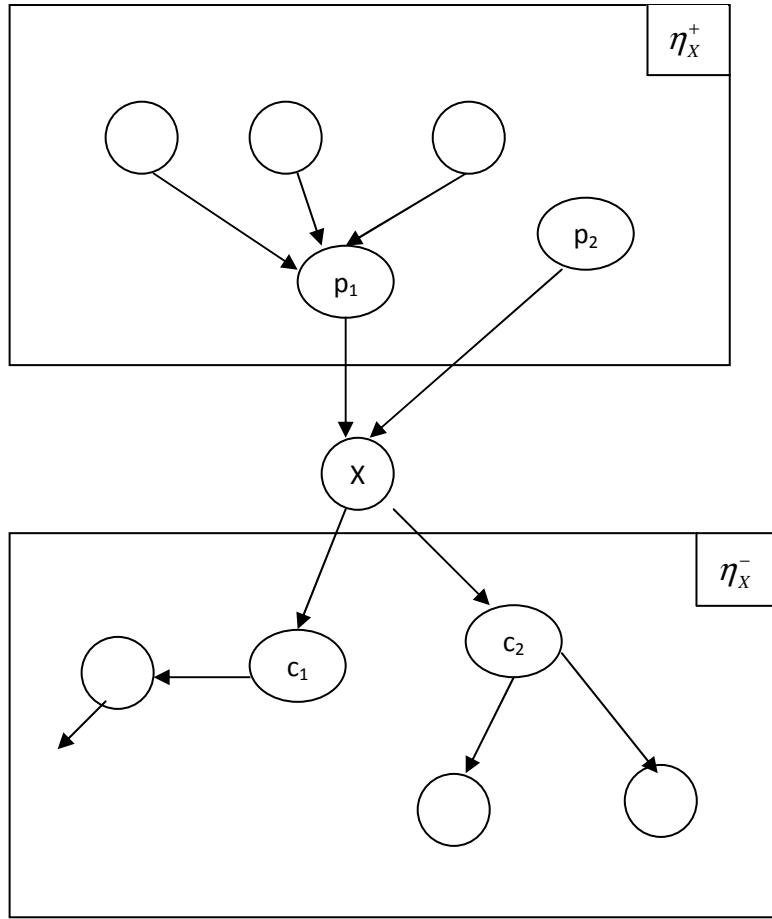


Figure 112 : Division en deux parties de l'ensemble des nœuds d'un graphe par rapport à un nœud particulier

où

- β est la facteur de normalisation,
- le calcul du vecteur $\lambda(X)$ nécessite la connaissance des valeurs λ des fils de X et de leur probabilité conditionnelle. Il est calculé à partir de la formule suivante :

$$\lambda(X) = \prod_{f \in \text{fils}(X)} \sum_{t \in f} \lambda(t).P(t | X). \quad (9)$$

- le calcul de la valeur de $\pi(X)$ nécessite la connaissance des valeurs π des parents de X et de leur probabilités conditionnelles :

$$\pi(X) = \prod_{f \in \text{fils}(X)} \sum_{t \in f} \pi(t).P(X | t) \quad (10)$$

A.3 : Méthodes d'apprentissage

Les méthodes d'apprentissage de réseau bayésien sont bien détaillées dans [Becker, 1999], [Corméjols, 2002] et [Naim, 2004].

Un réseau bayésien est défini d'une part par sa structure (graphe orienté sans cycle) et d'autre part par ses paramètres (tables des probabilités).

L'objectif de *l'apprentissage de la structure du réseau* est de trouver les indépendances conditionnelles entre les variables aléatoires qui représentent les tâches à étudier, c'est à dire de préciser les relations de causes à effets pour construire le graphe causal. Plus la précision est fine, plus la structure est bonne et la détermination des paramètres moins complexes.

L'objectif de *l'apprentissage des paramètres du réseau* est la traduction des relations des dépendances entre les variables aléatoires du graphe dont la structure est connue par ses tables de probabilités.

Méthodes d'apprentissage des paramètres à partir de données complètes et incomplètes

L'apprentissage des paramètres estime les distributions de probabilités, c'est-à-dire les tables de probabilités conditionnelles ou les fortes relations entre les états des nœuds, à partir des données disponibles, données pouvant être complètes ou incomplètes. L'estimation de ces distributions de probabilités paramétriques ou non est un domaine de recherche vaste et complexe. Nous ne décrivons ci-après que les méthodes les plus utilisées dans le cadre des réseaux bayésiens.

- Apprentissage des paramètres à partir de données complètes

Nous supposons que les variables du réseau bayésien sont observées. La méthode d'estimation des distributions de probabilités la plus utilisée est celle qui estime la probabilité d'un événement par sa fréquence d'apparition dans la base des données. Elle repose sur la recherche du maximum de vraisemblance selon la formule :

$$P(X_i = x_k | Pa(X_i) = c_j) = \theta_{i,j,k} = \frac{N_{i,j,k}}{\sum_k N_{i,j,k}} \quad (11)$$

où $N_{i,j,k}$ est le nombre d'événements dans la base des données pour lequel la variable X_i est dans l'état x_k et ses parents sont dans la configuration c_j .

- *apprentissage des paramètres à partir de données incomplètes* (apprentissage statistique) : Dans la plupart des applications, les données sont incomplètes : certaines variables d'intérêts du système à étudier ne sont pas observables. La méthode alors utilisée est basée sur une méthode itérative de maximisation de l'espérance (« Expectation Maximisation ») [Becker, 1999], [Naim, 2004].

Soient :

- $X_o = \{X_o^p\}_{p=1 \dots N}$ l'ensemble des données observées,
- $\theta^{(t)} = \{\theta_{i,j,k}^{(t)}\}$ les paramètres du réseau bayésien à l'itération t .

L'algorithme de maximisation de l'espérance se décline ainsi :

- *calcul de l'espérance*. L'espérance est l'estimation des $N_{i,j,k}$ manquantes. Elle est obtenue en calculant leur moyenne conditionnellement aux données et aux paramètres courants du réseau :

$$N_{i,j,k}^* = E[N_{i,j,k}] = \sum_{p=1}^N P(X_i = x_k | Pa(X_i) = c_i, X_o^p, \theta^{(t)}), \quad (12)$$

Cette étape passe par la réalisation d'une succession d'inférences qui utilise les paramètres courants du réseau et remplace les valeurs manquantes par les probabilités obtenues par inférence.

- *calcul de la maximisation de vraisemblance.* La maximisation de vraisemblance est calculée en remplaçant les $N_{i,j,k}$ manquants par leur valeur moyenne calculée précédemment. Les nouveaux paramètres θ^{t+1} obtenus par l'approche de maximum de vraisemblance sont :

$$\theta_{i,j,k}^{t+1} = \frac{N_{i,j,k}^*}{\sum_k N_{i,j,k}^*} \quad (13)$$

- les deux étapes précédentes sont itérées tant que $|\theta^t - \theta^{t-1}| \geq \varepsilon$.
- *apprentissage des paramètres à partir de données incomplètes* (apprentissage bayésien) : L'algorithme EM reste applicable dans le cadre bayésien, en changeant le maximum de vraisemblance de l'étape de maximisation M par un maximum (ou une espérance) *a posteriori*. Dans ce cas là, l'espérance *a posteriori* est définie par :

$$\theta_{i,j,k}^{(t+1)} = \frac{N_{i,j,k}^* + \alpha_{i,j,k}}{\sum_k N_{i,j,k}^* + \alpha_{i,j,k}} \quad (14)$$

$\alpha_{i,j,k} = 1$, pour une distribution de Dirichlet uniforme.

Méthodes d'apprentissage de la structure à partir de la relation de causalité ou de l'étude des vraisemblances (algorithme du score) du réseau bayésien

On suppose ici la structure du réseau connue. L'apprentissage de la structure a pour objet la recherche du meilleur graphe représentant le système à étudier.

La première étape de la méthode est la recherche des différentes relations de causalités entre les variables. L'étape suivante consiste à quantifier l'adéquation de chaque réseau bayésien au système, un score est alors associé à chaque réseau bayésien. La structure la plus en adéquation avec le système est celle dont le graphe a obtenu le meilleur score.

Pour résoudre ce problème, [Becker, 1999][Corméjols, 2002] ont proposé des solutions basées sur l'heuristique de recherche dans l'espace des graphes, qui restreignent cet espace à l'espace des arbres, ordonnent les nœuds pour limiter la recherche des parents possibles pour chaque variables.

- *apprentissage de la causalité*

Le principe de cette approche est basée sur :

- a- une construction d'un graphe non dirigé, contenant les relations entre les variables, à partir d'un test d'indépendance conditionnelle
- b- une détection de N-structures (en utilisant aussi les tests d'indépendance conditionnelle)
- c- une propagation des orientations de certains arcs.

L'essentielle de toutes ces techniques requise sur la détermination à partir des données disponibles les relations d'indépendances conditionnelles entre deux variables quelconques conditionnelles à un ensemble de variables.

- algorithme de score

Cette approche basée soit sur la recherche de la structure qui maximise un certaine score, soit à rechercher les meilleures structures et combiner leurs résultats.

A.4 : Extension des réseaux bayésiens au cas dynamique : réseaux bayésiens dynamiques

Les réseaux bayésiens statiques sont utilisés pour résoudre ou modéliser des problèmes statiques. Ils ne conviennent pas aux systèmes dynamiques.

Les réseaux bayésiens dynamiques sont une extension des réseaux bayésiens statiques pour laquelle les modèles de distributions des probabilités ont une représentation dynamique [Murphy, 2002].

Dans un système à temps discret, ce qui sera notre cas, à chaque nouvelle observation, l'indice t d'un nœud $N_j(t)$ est incrémenté de 1. La structure du réseau (ou graphe) reste inchangé entre deux instants successifs (t et $t+1$). En revanche, les tables des probabilités conditionnelles sont généralement réactualisées. Cette réactualisation est réalisée en utilisant des probabilités temporelles de transition (figure 113). Les tables de probabilités conditionnelles qui correspondent à chaque nœud du graphe sont définies à chaque instant. Ceci est également vrai pour les réseaux bayésiens dont les nœuds dépendent de plusieurs instants successifs (figure 113). Le réseau bayésien dynamique respecte la propriété de la chaîne de Markov cachée : l'étape courante dépend uniquement de l'étape qui la précède directement [Murphy, 2002].

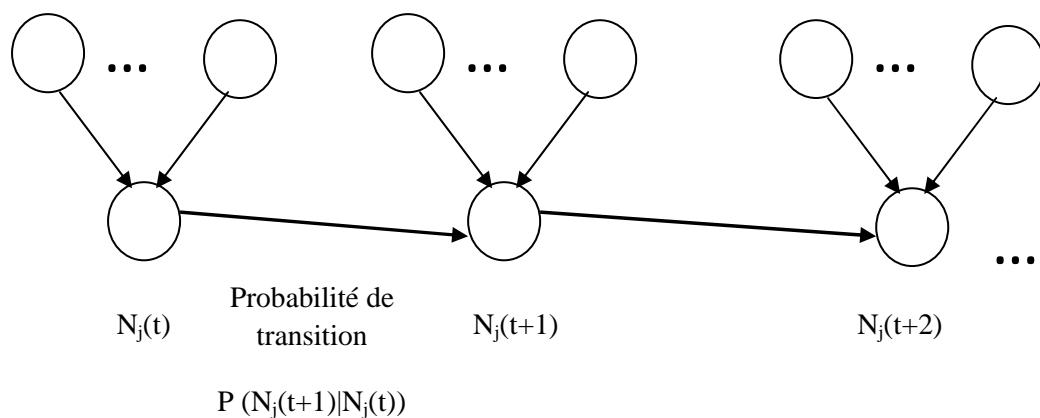


Figure 113 : Structure d'un réseau bayésien dynamique.

La création d'un réseau bayésien dynamique basée sur des données dépend de la connaissance complète ou non des données et de celle ou non de la structure. Quatre cas sont ainsi distingués :

- données complètes (les valeurs des variables sont connues) et structure connue ;
- données incomplètes (des valeurs de variables ne sont pas connues) et structure connue ;
- données complètes et structure inconnue ;
- données incomplètes (ou partielles) et structure inconnue.

Dans le cas de « *données complètes et de structure connu* », il s’agit de trouver les valeurs des paramètres de chaque distribution de probabilités conditionnelles qui maximise la vraisemblance basée sur les données de formation.

Dans le cas de « *données incomplètes et de structure connue* », plusieurs variables ne sont pas observables, l'espace de vraisemblance devient multimodal et des méthodes itératives doivent être utilisées, telles que celle de maximisation de l'espérance (« Expectation Maximization ») pour trouver un maximum local de la fonction de Maximum de vraisemblance ou de Maximum *a posteriori*.

Dans le cas de « *données complètes et de structure inconnue* », le nombre et type des états du réseau sont connus, mais les relations entre ces états ne le sont pas. Il s’agit alors de trouver une méthode de construction de la structure du réseau bayésien dynamique en se basant sur les données observées et la connaissance de l’expert du domaine d’étude.

Dans le cas de « *données incomplètes (ou partielles) et de structure inconnue* », les données sont incomplètes, l’observabilité du système est complexe et incomplète, l’utilisation d’un outil puissant pour aider l’intégration de l’ensemble des informations incomplètes récoltées peut être utile. L’algorithme de maximisation de l’espérance est souvent utilisé pour simplifier ce problème [Heckerman, 1995].

Une fois le modèle du réseau bayésien dynamique construit, les méthodes de résolution utilisées pour les réseaux bayésiens statiques sont applicables, mais ici dans le domaine temporel.

Dans notre domaine de recherche, on utilisera des réseaux bayésiens statiques et dynamiques simples dont les données peuvent être incomplètes mais dont on fixe la structure.

Annexe B : Détermination statistique de l'invariant pour la détection

Nous cherchons à déterminer l'écart type $\sigma_{S_{i,voisinage}}$ sur l'invariant pour un impact i avec une valeur de *voisinage* de part et d'autre, afin de pouvoir établir une grandeur statistique du seuil permettant de définir si les $(2*voisinage+1)$ impacts répondent bien à l'invariant (la droite). Pour cela, définissons un impact i comme étant une grandeur déterministe ρ_i (la mesure de distance) associée à un bruit blanc gaussien γ .

Nous proposons tout d'abord d'établir un résultat pour un *voisinage* 1, soit trois impacts, puis nous généraliserons aisément. Soit $A = S_{i,1}$, l'invariant de la formule (7) du chapitre III. Nous avons donc :

$$\begin{aligned}
 A &= \frac{\frac{1}{\rho_{i-1} + \gamma_{i-1}} + \frac{1}{\rho_i + \gamma_i} + \frac{1}{\rho_{i+1} + \gamma_{i+1}}}{\frac{1}{\rho_i + \gamma_i}} = 1 + \frac{\rho_i + \gamma_i}{\rho_{i-1} + \gamma_{i-1}} + \frac{\rho_i + \gamma_i}{\rho_{i+1} + \gamma_{i+1}} \\
 A &= 1 + \frac{\rho_i}{\rho_{i-1} + \gamma_{i-1}} + \frac{\rho_i}{\rho_{i+1} + \gamma_{i+1}} + \frac{\gamma_i}{\rho_{i-1} + \gamma_{i-1}} + \frac{\gamma_i}{\rho_{i+1} + \gamma_{i+1}} \\
 A &= 1 + \frac{\rho_i}{\rho_{i-1}} \cdot \frac{1}{1 + \frac{\gamma_{i-1}}{\rho_{i-1}}} + \frac{\rho_i}{\rho_{i+1}} \cdot \frac{1}{1 + \frac{\gamma_{i+1}}{\rho_{i+1}}} + \frac{\gamma_i}{\rho_{i-1}} \cdot \frac{1}{1 + \frac{\gamma_{i-1}}{\rho_{i-1}}} + \frac{\gamma_i}{\rho_{i+1}} \cdot \frac{1}{1 + \frac{\gamma_{i+1}}{\rho_{i+1}}}
 \end{aligned}$$

Nous obtenons donc :

$$A = 1 + \frac{\rho_i + \gamma_i}{\rho_{i-1}} + \frac{1}{1 + \frac{\gamma_{i-1}}{\rho_{i-1}}} + \frac{\rho_i + \gamma_i}{\rho_{i+1}} + \frac{1}{1 + \frac{\gamma_{i+1}}{\rho_{i+1}}}$$

En remarquant que $\frac{1}{1+x} \approx 1-x$ pour $|x| \ll 1$

On peut se poser la question si cette approximation est utilisable dans notre cas.

Prenons l'hypothèse $\frac{\gamma_{i-1}}{\rho_{i-1}} \ll 1$. Un impact ρ_{i-1} à 30 mètres avec une imprécision σ_ρ de 0,1m (bruit fort), nous avons : $\frac{\gamma_{i-1}}{\rho_{i-1}} \approx 0,03$.

Prenons $\frac{\gamma_{i-1}}{\rho_{i-1}} \leq \frac{2\sigma_\rho}{\rho_{i-1}}$ (soit une probabilité prenant en compte de 97% des valeurs)
 (Pour $\frac{1}{1+x} = 1-x$ avec $x = 0,1$, on tolère donc 1% d'erreur.

Donc $\frac{\gamma_{i-1}}{\rho_{i-1}} \leq \frac{2\sigma_\rho}{\rho_{i-1}} \leq 0,1 \Rightarrow \rho_{i-1} \geq \frac{2\sigma_\rho}{0,1}$. Cette condition est peu contraignante puisque pour un bruit

dans une gamme élevé (pour des télémètres lasers) de 0.1m, nous devons avoir une mesure à plus de 2m, ce qui semble indispensable pour une utilisation de capteurs embarqués sur des véhicules en utilisation d'aide à la conduite.

Nous avons donc $A = 1 + \frac{\rho_i + \gamma_i}{\rho_{i-1}} \cdot \left(1 - \frac{\gamma_{i-1}}{\rho_{i-1}}\right) + \frac{\rho_i + \gamma_i}{\rho_{i+1}} \cdot \left(1 - \frac{\gamma_{i+1}}{\rho_{i+1}}\right)$

$$A = 1 + \frac{\rho_i}{\rho_{i-1}} - \frac{\rho_i \gamma_{i-1}}{(\rho_{i-1})^2} + \frac{\gamma_i}{\rho_{i-1}} - \frac{\gamma_i \gamma_{i-1}}{(\rho_{i-1})^2} + \frac{\rho_i}{\rho_{i+1}} + \frac{\gamma_i}{\rho_{i+1}} - \frac{\gamma_i \gamma_{i+1}}{(\rho_{i+1})^2} + \frac{\rho_i \gamma_{i+1}}{(\rho_{i+1})^2}$$

Déterminons maintenant la moyenne et la variance de cette valeur :

Pour la moyenne $E(A)$: $E(A) = 1 + \frac{\rho_i}{\rho_{i-1}} + \frac{\rho_i}{\rho_{i+1}}$

$$\frac{1}{\rho_{i-1}} + \frac{1}{\rho_i} + \frac{1}{\rho_{i+1}}$$

Or nous avons défini dans le paragraphe III.6.1 que, en l'absence de bruit $\frac{\frac{1}{\rho_{i-1}} + \frac{1}{\rho_i} + \frac{1}{\rho_{i+1}}}{\rho_i} = Cste$

Donc $E(A) = Cste = C_0 = S_{1_{théorique}}$ donné par l'équation (8) du chapitre III.

Pour la variance $var(A) = E(A^2) - E(A)^2$:

$$A = \left(1 + \frac{\rho_i}{\rho_{i-1}} + \frac{\rho_i}{\rho_{i+1}}\right) + \gamma_i \left(\frac{1}{\rho_{i-1}} + \frac{1}{\rho_{i+1}}\right) - \frac{1}{(\rho_{i-1})^2} [\rho_i \gamma_{i-1} + \gamma_i \gamma_{i-1}] - \frac{1}{(\rho_{i+1})^2} [\rho_i \gamma_{i+1} + \gamma_i \gamma_{i+1}]$$

soit $A = C_0 + \frac{\gamma_i}{\rho_i} (1 - C_0) - \frac{1}{\rho_{i-1}^2} (\rho_i \gamma_{i-1} + \gamma_i \gamma_{i-1}) - \frac{1}{\rho_{i+1}^2} (\rho_i \gamma_{i+1} + \gamma_i \gamma_{i+1})$

En développant :

$$A^2 = C_0^2 + \underbrace{\gamma_i^2 (1 - C_0)^2}_{B_1} - \underbrace{\frac{1}{(\rho_{i-1})^4} [\rho_i \gamma_{i-1} + \gamma_i \gamma_{i-1}]^2}_{B_2} - \underbrace{\frac{1}{(\rho_{i+1})^4} [\rho_i \gamma_{i+1} + \gamma_i \gamma_{i+1}]^2}_{B_3}$$

$$+ \underbrace{2C_0 (1 - C_0) \gamma_i}_{B_4} - \underbrace{\frac{2C_0}{(\rho_{i-1})^2} [\rho_i \gamma_{i-1} + \gamma_i \gamma_{i-1}]}_{B_5}$$

$$- \underbrace{\frac{2C_0}{(\rho_{i+1})^2} [\rho_i \gamma_{i+1} + \gamma_i \gamma_{i+1}]}_{B_6} - \underbrace{\frac{2\gamma_i (1 - C_0)}{(\rho_{i-1})^2} [\rho_i \gamma_{i-1} + \gamma_i \gamma_{i-1}]}_{B_7}$$

$$- \underbrace{\frac{2\gamma_i (1 - C_0)}{(\rho_{i+1})^2} [\rho_i \gamma_{i+1} + \gamma_i \gamma_{i+1}]}_{B_8}$$

$$+ \underbrace{\frac{2}{(\rho_{i+1})^2 (\rho_{i-1})^2} [\rho_i \gamma_{i-1} + \gamma_i \gamma_{i-1}] [\rho_i \gamma_{i+1} + \gamma_i \gamma_{i+1}]}_{B_9}$$

Et en déterminant l'espérance terme à terme, nous obtenons :

$$E(B_1) = (C_0 - 1)^2 \frac{\sigma_\rho^2}{\rho_i^2}, \quad E(B_2) = \frac{1}{\rho_{i-1}^4} (\rho_i^2 \sigma_\rho^2 + \sigma_\rho^4), \quad E(B_3) = \frac{1}{\rho_{i+1}^4} (\rho_i^2 \sigma_\rho^2 + \sigma_\rho^4), \quad E(B_4) = 0,$$

$$E(B_5) = 0, \quad E(B_6) = 0, \quad E(B_7) = 0, \quad E(B_8) = 0 \text{ et } E(B_9) = 0$$

Soit donc :

$$E(A^2) = C_0^2 + (1 - C_0)^2 \frac{\sigma_\rho^2}{\rho_i^2} + \frac{1}{\rho_{i-1}^4} (\rho_i^2 \sigma_\rho^2 + \sigma_\rho^4) + \frac{1}{\rho_{i+1}^4} (\rho_i^2 \sigma_\rho^2 + \sigma_\rho^4)$$

Donc :

$$\text{var}(A) = E(A^2) - E(A)^2 = (1 - C_0)^2 \frac{\sigma_\rho^2}{\rho_i^2} + \frac{1}{\rho_{i-1}^4} (\rho_i^2 \sigma_\rho^2 + \sigma_\rho^4) + \frac{1}{\rho_{i+1}^4} (\rho_i^2 \sigma_\rho^2 + \sigma_\rho^4)$$

D'après l'équation (8) du chapitre III, $C_0 = 1 + 2 \cos \alpha$, avec α le pas angulaire.

En négligeant l'ensemble des termes en $\frac{1}{\rho_{i-1}^4}$ et $\frac{1}{\rho_{i+1}^4}$, on obtient une approximation pour la variance :

$$\text{var}(A) \approx (1 - C_0)^2 \frac{\sigma_\rho^2}{\rho_i^2}$$

Soit donc une approximation de l'erreur sur l'invariant (avec α de l'ordre de 1° ou moins) :

$$\sigma_{S_{i,1}} \approx \frac{\sigma_\rho}{\rho_i} \cdot |1 - C_0| = 2 \frac{\sigma_\rho}{\rho_i} \cdot |\cos \alpha| = 2 \frac{\sigma_\rho}{\rho_i} \cos \alpha$$

En généralisant pour un voisinage quelconque, nous obtenons assez facilement :

$$\sigma_{S_{i,voisinage}} \approx 2 \frac{\sigma_\rho}{\rho_i} \cdot \left| 1 - S_{voisinage_{théorique}} \right| = 2 \frac{\sigma_\rho}{\rho_i} \cdot \sum_{j=1}^{voisinage} \cos j\alpha$$

où ρ_i représente le point central de l'ensemble des points répondant au critère de l'invariant.

Bibliographie

- [ACE_URL] ACEA European Automobile Manufacturers' Association, « *About us* », page disponible au 1^{er} septembre, (2008), à l'URL http://www.acea.be/index.php/about_us.
- [AHS_URL] AHSRA (Advanced Cruise-Assist Highway system research association), « *International task force on Vehicle-Highway Automation (ITFVHA), 5th Annual Meeting, A participant's report; October 4-5 2001* », disponible au 1er septembre, (2008), à l'URL http://www.ahsra.or.jp/eng/d01e/2001/9e_itf_5.htm.
- [Alempijevic, 2004] A. Alempijevic, « *High-speed feature extraction in sensor coordinates for laser rangefinders* », In Proc. of the 2004 Australasian Conference on Robotics and Automation, Canberra, Australie (2004).
- [Anderson, 1979] B. D. O. Anderson, J. B. Moore, « *Optimal Filtering* », Prentice Hall, Englewood Cliffs, N. J. USA, (1979).
- [ARC_URL] ARCOS (Action de Recherche pour une Conduite Sécurisée), Site disponible au 1^{er} septembre, (2008), à l'URL <http://www.arcos2004.com/>.
- [Arras, 1998] K.A. Arras, « *An introduction to Error Propagation : Derivation, Meaning and Examples of equation $C_Y = F_X C_X F_X^T$* », Technical Report n° EPFL-ASL-TR-98-01 R3 of Autonomous Systems Lab, Institute of Robotic Systems, EPFL (1998).
- [Arulampalam, 2002] S. Arulampalam, S. Maskell, N. Gordon, T. Clapp, « *A tutorial on particle filters for on-line non-linear / non-Gaussian Bayesian tracking* », IEEE Transactions on Signal Processing, 50(2):174–188, february, (2002).
- [Aufrère, 2000] R. Aufrère, F. Marmoiton, R. Chapuis, F. Collange, J. P. Dérutin, « *Détection de route et suivi de véhicules par vision pour l'ACC* », Traitement du signal, Vol. 17, No. 3, (2000).
- [AUT_URL] Autocruise company, <http://www.adaptive-cruise-control.com/html.php> site valide au 1er septembre, (2008).
- [Barbaresco, 1996] F. Barbaresco, J. Lambert, C. Lambert, « *Segmentation spatio-temporelle et suivi dynamique des fouillis radar* », Traitement du Signal, vol. 13, n° 5, pp. 449-536 (1996).
- [Bar-Shalom, 1988] Y. Bar-Shalom, T.E. Fortmann, « *Tracking and Data Association* », Academic Press, (1988).
- [Bar-Shalom, 1993] Y. Bar-Shalom, X. R. Li, « *Estimation and Tracking : Principles, Techniques and Software* », Artech House, (1993).
- [Becker, 1999] A. Becker, P. Naïm, « *Les réseaux bayésiens : modèles graphiques de connaissance* », Edition Eyrolles, (1999).
- [Bennetti, 2006] S. Bennetti, « *I-WAY – Intelligent co-operative system in cars for road safety –D1.2 State of the Art* », IST-4-027195 Project (Information Society Technologies Programme), DG INFSO, 300 pages, 25 juillet, (2006),

- disponible au 1er août, (2008), sur : <http://www.iway-project.eu/Deliverables.aspx>.
- [Besesty, 1999] P. Besesty, « *Télémètre à laser puce* », Dossier : R1811_03_1999. Date de parution : 03/1999 Disponible dans la base : Archives Analyse / mesures. http://www.techniques-ingenieur.fr/dossier/telemetre_a_laser_puce/R1811_03_1999.
- [Blackman, 1986] S. Blackman, « *Multiple-Target Tracking with Radar Applications* », Norwood, MA : Artech House, (1986).
- [Borges, 2004] Borges, G.A., M.-J. Aldon, « *Line Extraction in 2D Range Images for Mobile Robotics* », Journal of Intelligent and Robotic Systems, vol. 40, n° 3, pp. 267-297 (2004).
- [Bouveyron, 2006] C. Bouveyron, « *Modélisation et classification des données de grande dimension : application à l'analyse d'images* », thèse, Mathématiques Appliquées, Université Joseph Fourier-Grenoble 1, septembre, (2006).
- [Brassart, 2005] Eric Brassart, Philippe Bonnifait, « *Projet SAACAM – Systèmes Actifs d'Aide à la Conduite pour Améliorer la sécurité automobile* », 2000-2004, avril, (2005), transparents disponibles au 1^{er} août sur http://www.hds.utc.fr/diva/JourneesAvril2005/5avril2005/07_Projet_SAACAM.pdf.
- [Carvalho, 1997] H. Carvalho, P. Del Moral, A. Monin, G. Salut, « *Optimal non-linear filtering in GPS/INS integration* », IEEE Transactions on Aerospace and Electronic Systems, 33(3), (1997).
- [Cemgil, 2003] A.T. Cemgil, B. Kappen, « *Monte Carlo methods for tempo tracking and rhythm quantization* », Journal of Artificial Intelligence Research, 18:45–81, january, (2003).
- [Corméjols, 2002] A. Corméjols, L. Miclet, Y. Kodratoff, « *Apprentissage artificiel : Concepts et algorithmes* », Edition Eyrolles, (2002).
- [Coué, 2003] C. Coué, « *Modèle bayésien pour l'analyse multimodale d'environnements dynamiques et encombrés : Application à l'assistance à la conduite en milieu urbain* », Thèse de doctorat INPG (Institut National Polytechnique de Grenoble), (2003).
- [Crowley, 1989] J. Crowley, « *World modelling and position estimation for a mobile robot using ultrasonic ranging* », Proceedings of IEEE Conference on Robotics and Automation, Scottsdale, p.674-680, may, (1989).
- [Dambreville, 2001] F. Dambreville, « *Optimisation de la gestion des capteurs et des informations pour un système de détection* », Thèse de L'Université de Rennes 1 (2001).
- [Darricau, 1981] J. Darricau, « *Physique et Théorie du Radar* », Editions Sodipe (1981).
- [Deram, 2007] R. Deram, « *Capteur Laser à Rotation Multi-tir de chez IBEO et ses Interfaces* », stagiaire INRETS, Rapport de stage de première année de MASTER EIM de l'Université ULCO, 30 pages, Réf. : INRETS/RE-07-713-FR, août, (2007).
- [Dietmayer, 2001] K. Dietmayer, J. Sparbert, D. Streller, « *Model based Object Classification and Object Tracking in Traffic scenes from Range Images* », Proc. of 4th IEEE Intelligent Vehicles Symposium, Tokyo (2001).
- [Dietmayer, 2005] K. Dietmayer; Kaempchen, N.; Fuerstenberg, K. Ch.; Kibbel, J.; Justus, W., Schulz, R., « *Roadway Detection and Lane Detection using Multilayer Laserscanner* », Proceedings of AMAA 2005, 9th International Conference

- on Advanced Microsystems for Automotive Applications, Berlin, Germany, mars, (2005).
- [Doucet, 1998] A. Doucet, « *On sequential simulation-based methods for Bayesian filtering* », Technical Report CUED/F-INFENG/TR.310, Signal Processing Group, Department of Engineering, University of Cambridge, (1998).
- [Doucet, 2002] A. Doucet, N. de Freitas, N. Gordon, « *Sequential Monte-Carlo Methods in Practice* », Springer Verlag, (2002).
- [EIS_URL] Europe's Information Society Thematic Portal, « *Activities: eSafety* », page disponible au 1er septembre, (2008), http://ec.europa.eu/information_society/activities/esafety/index_en.htm
- [ERT_URL] ERTICO-IST Europe, « *Mission & Vision* », page disponible au 1er septembre, (2008), à l'URL http://www.ertico.com/en/about_ertico/mission_vision/.
- [eSafety, 2008] « *eSafety – Améliorer la sécurité routière grâce aux technologies de l'information et des communications* », fiche d'information générale 48 de mai, (2008), disponible au 1^{er} septembre, (2008), à l'URL. http://ec.europa.eu/information_society/doc/factsheets/048-esafety-fr.pdf.
- [Estève, 1995] D. Estève, G. Vialaret, « *L'intégration des systèmes électroniques dans l'automobile du XXI siècle* », Ouvrage collectif coordonné par D. Estève, A. Coustre, M. Guarajedagui, Edité par Cepadues, pp. 39-44, juin, (1995).
- [FEH_URL] FEHRL (Forum of European National Highway Research Laboratories), <http://www.fehrl.org/>, site disponible au 1^{er} septembre, (2008).
- [Flament, 2004] M. Flament, G. Fleury, M.-E. Davoust, « *Particle filter and Gaussianmixture filter efficiency evaluation for terrain-aided navigation* », In *EUSIPCO*, pp.605–608, (2004).
- [Fortmann, 1983] T. E. Fortmann, Y. Bar-Shalom, M. Scheffe, « *Sonar Tracking of Multiple Targets Using Joint Probabilistic Data Association* », IEEE Journal of Oceanic Engineering, Vol.8, No. 3, july, (1983).
- [Freeman, 1998] M. Freeman, « *Decisions Trees* », dans *DBMS Data Mining Solutions Supplement*, disponible sur <http://www.dbmsmag.com/9807m05.html>, 1998
- [Fuerstenberg, 2001a] Fuerstenberg, K. Ch., Willhoeft, V., « *Object Tracking and Classification using Laserscanners - Pedestrian Recognition in Urban Environment* », Proceedings of ITSC 2001, IEEE 4th International Conference on Intelligent Transport Systems, Oakland, USA, august, (2001).
- [Fuerstenberg, 2001b] Fuerstenberg, K. Ch., Willhoeft, V., « *Pedestrian Recognition in Urban Traffic using Laserscanners* », Proceedings of ITS 2001, 8th World Congress on Intelligent Transport Systems, Sydney, Australia, october, (2001).
- [Fuerstenberg, 2001c] Fuerstenberg, K. Ch.; Willhoeft, V., Dietmayer, K. C. J., « *New Sensor for 360° Vehicle Surveillance - Innovative Approach to Stop & Go, Lane Assistance and Pedestrian Recognition* », Proceedings of IV 2001, IEEE Intelligent Vehicles Symposium, Tokio, Japan. mai, (2001).
- [Fuerstenberg, 2001d] Fuerstenberg, K. Ch., Willhoeft, V., « *New Laserscanner for driver assistance* », Proceedings of 8th EAEC European Automotive Congress, Bratislava, Slovakia. juin, (2001).
- [Fuerstenberg, 2001e] K. Ch. Fuerstenberg, P. Baraud, G. Caporaletti, S. Citelli, Z. Eitan, U. Lages, C. Lavergne, « *Development of a Pre-Crash sensorial system – the CHAMELEON Project* », VDI, Wolfsburg, (2001).

- [Fuerstenberg, 2002a] Fuerstenberg, K. Ch.; Dietmayer, K. C.J., Willhoefft, V., « *Pedestrian Recognition in Urban Traffic using a vehicle based Multilayer Laserscanner* », Proceedings of IV 2002, IEEE Intelligent Vehicles Symposium, Versailles, France, juin, (2002).
- [Fuerstenberg, 2002b] Fuerstenberg, K. Ch.; Dietmayer, K. C.J.; Eisenlauer, S., Willhoefft, V., « *Multilayer Laserscanner for robust Object Tracking and Classification in Urban Traffic Scenes* », Proceedings of ITS 2002, 9th World Congress on Intelligent Transport Systems, Chicago, USA, novembre, (2002).
- [Fuerstenberg, 2003a] Fuerstenberg, K. Ch.; Dietmayer, K. C.J., Lages, U., « *Laserscanner Innovations for Detection of Obstacles and Road* », Proceedings of AMAA 2003, 7th International Conference on Advanced Microsystems for Automotive Applications, Berlin, Germany, mai, (2003).
- [Fuerstenberg, 2003b] Fuerstenberg, K. Ch., Lages U., « *Pedestrian Detection and Classification by Laserscanners* », Proceedings of 9th EAEC International Congress, Paris, France, juin, (2003).
- [Fuerstenberg, 2003c] Fuerstenberg, K. Ch.; Linzmeier, D. T., Dietmayer, K. C.J., « *Pedestrian Recognition and Tracking of Vehicles using a vehicle based Multilayer Laserscanner* », Proceedings of ITS 2003, 10th World Congress on Intelligent Transport Systems, Madrid, Spain, novembre, (2003).
- [Fuerstenberg, 2004] Fuerstenberg, K. Ch., Dietmayer, K. C.J., « *Object Tracking and Classification for Multiple Active Safety and Comfort Applications using Multilayer Laserscanner* », Proceedings of IV 2004, IEEE Intelligent Vehicles Symposium, Parma, Italy, juin, (2004).
- [Fuerstenberg, 2006] Fuerstenberg, K., Schulz, R., « *Laserscanner for Driver Assistance* », Proceedings of WIT 2006, 3rd International Workshop on Intelligent Transportation, Hamburg, mars, (2006).
- [Giai-Checa, 1993] B. Giai-Checa, P. Bouthemy, T. Vieville, « *Detection d'objets en mouvement* », rapport de recherche N°1906, Robotique, Image et Vision, INRIA Sophie Antipolis, juin, (1993).
- [Giesler, 1998] B. Giesler, R. Graf, R. Dillman, C.F.R. Weiman, « *Fast mapping using the Log-Hough transformation* », in Proc. of IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, vol. 3, pp. 1702-1707 (1998).
- [Gordon, 1993] N. J. Gordon, D. J. Salmond, A. F. M. Smith, « *Novel approach to nonlinear/ non-Gaussian Bayesian state estimation* », IEE Proceedings-F, 140(2), avril, (1993).
- [Heckerman, 1995] D. Heckerman, D. Geiger, and D. M. Chickering, « *Learning Bayesian networks: The combination of knowledge and statistical data* ». In *Machine Learning*, 20:197-243, (1995).
- [IBEO_URL] IBEO Automobile Sensor GmbH, <http://www.ibeo-as.com/english/default.asp>, lien valide au 1^{er} août, (2008).
- [INRETS, 2005] INRETS, « *Sur la route... la sécurité – Paroles de chercheurs* », 20 ans de recherché à l'INRETS, 1985-2005, dans les collections de l'INRETS, ISSN 0768-9756, ISBN 2-85782-633-8, 122 pages, novembre, (2005).
- [Isard, 1998] M. Isard, A. Blake, « *Condensation - conditional density propagation for visual tracking* », International Journal of Computer Vision, 29(1):5–28, (1998).
- [Izri, 2004a] S. Izri, E. Brassart, L. Delahoche, A. Clérentin, « *Détection de véhicules dans un environnement autoroutier à l'aide de données télémétriques et*

- visuelles »; Revue ISDM (Revue permanente en ligne des utilisateurs des Technologies de l'Information et de la Communication, ISDM n°13 – février, (2004), Spécial MAJECSTIC'03, téléchargeable au 1^{er} août, (2008), sur http://isdm.univ-tln.fr/articles/num_archives.htm#isdm13
- [Izri, 2004b] S. Izri, E. Brassart, L. Delahoche, B. Marhic, Fabrice de Chaumont, « *Segmentation des données visuelles et télémétriques- Application pour la détection de véhicules en milieu autoroutier* »; MAJECSTIC'04 (MANifestation des JEunes Chercheurs STIC), (2004), téléchargeable au 1^{er} août, (2008), sur http://www-lil.univ-littoral.fr/~lewandowski/majecstic/articles/art_13_2_2_izri.pdf.
- [Jain, 1999] A. K. Jain, M. N. Murty, P. J. Flynn, « *Data clustering : A review* », ACM Computing Surveys, Vol. 31, No. 3, september, (1999).
- [Jardino, 2005] M. Jardino, www.limsi.fr/Individu/jardino/c3-ii05.ppt, « *Fouille de données dans les corpus de textes classification* »
- [Jazwinsky, 1970] A. M. Jazwinsky, « *Stochastic Processes and Filtering Theory* », Academic Press, New York, USA, (1970).
- [Jida, 2006] B. Jida, R. Lherbier, M. Wahl, D. Hamad, « *Détection automatique dans les données télémétriques et association spatio-temporelle par réseaux bayésiens. Application au suivi de véhicules* », Nat. Conf. MajecStic, Lorient, France, (2006).
- [Jida, 2007a] B. Jida, R. Lherbier, M. Wahl, D. Hamad, « *Suivi de véhicules par radar avec intégration de l'association probabiliste de données et des réseaux bayésiens* », Proc. of Conf. Systèmes Electroniques-Informatiques & Traitement de l'Information, pp. 197-202, Mohammadia, Maroc, (2007).
- [Jida, 2007b] B. Jida, R. Lherbier, M. Wahl, J.C. Noyer, « *Intégration du contexte par réseaux bayésiens dans une approche PDA : Application au suivi de véhicules* », Journée des doctorants INRETS, Villeneuve d'Ascq, avril, (2007).
- [Julier, 1997] S. J. Julier, J. K. Uhlmann, « *A new extension of the Kalman filter to nonlinear systems* », In SPIE Aerosense Symposium, Orlando, USA, april, (1997).
- [Kalman, 1960] R. S. Kalman, « *A new approach to linear filtering and prediction problems* », Transactions of the ASME, Series D. Journal of Basic Engineering, 82:35–45, (1960).
- [Keat, 2005] C.T.M. Keat, C. Pradalier, C. Laugier, « *Vehicle detection and park mapping using laser scanning* », in Proc. of the Int. Conf. of Intelligent Robots and Systems (IROS'05), pp. 2054-2060 (2005).
- [Kibbel, 2005] Kibbel, J.; Justus, W., Fuerstenberg, K. Ch, « *Lane Estimation and Departure Warning using Multilayer Laserscanner* ». Proceedings of WIT 2005, 2nd International Workshop on Intelligent Transportation, Hamburg, Germany. mars, (2005).
- [Labayrade, 2003] R. Labayrade, C. Royere, D. Gruyer, D. Aubert, « *Cooperative fusion for multi-objets detection with use of stereovision and laser scanner* », Int. Conf. IEEE ICAR, Sp. Session on Robotics Technologies for Intelligent Road Vehicles, Coimbra, Portugal, july, (2003).
- [Lanvin, 2004] P. Lanvin, « *Fusion multicapteurs pour la détection et le suivi de formes par filtrage particulaire: une approche dense* », thèse de doctorat de l'Université du Littoral Cote d'Opale, 8 décembre, (2004).

- [LAS_URL] « réseaulaser », Réseau laser en Rhône-Alpes amorcé par l'Agence Rhône-Alpes pour la Maîtrise des Matériaux, l'ARATEM, NOVELECT, le CNRS Rhône-Alpes, et Alpes Optique et Photonique, <http://laser.agmat.asso.fr/index.htm>, lien valide au 1^{er} août, (2008).
- [Laviola, 2003] J. Laviola, « *A comparison of unscented and extended Kalman filtering for estimating quaternion motion* », pp.2435–2440, Denver, Colorado, USA, june, (2003).
- [Lemonde, 2005] V. Lemonde, M. Devy, « *Détection d'objet par stéréovision sur véhicules intelligents* », 9èmes Journées Jeunes Chercheurs en Vision par Ordinateur (ORASIS'05), Fournols, France , mai, (2005).
- [LMS_URL] Documentation sur les capteur SICK LMS, <http://www.sick.com/home/factory/catalogues/auto/lmsoutdoor/en.html>, lien valide au 1er août, (2008).
- [LPR_URL] La Prévention Routière, association loi 1901 reconnue d'utilité publique, « →Statistiques d'accidents →Les grandes données de l'accidentologie », page disponible au 1^{er} septembre, (2008), à l'URL http://www.preventionroutiere.asso.fr/accidentologie_securite_routiere.aspx.
- [Macek, 2008] K. Macek, D. Alejandro, V. Govea, T. Fraichard, R. Siegwart, « *Safe Vehicle Navigation in Dynamic Urban Environments: A Hierarchical Approach* », Workshop on Planning, Perception and Navigation for Intelligent Vehicles, (2008). Version 1- 30 juillet, (2008), disponible sur <http://hal.inria.fr/inria-00308454/fr/>.
- [MacLachlan, 2006] R. MacLachlan, C. Mertz, « *Tracking of moving objects from a mobile vehicle using a scanning laser rangefinder* », Proc. of IEEE Intelligent Transportation System, pp. 301-306 (2006).
- [Mendes, 2004] A. Mendes, L. C. Bonto, U. Nunes, « *Multi-target detection and tracking with a laserscanner* », IEEE Intelligent Vehicles Symposium, Parma, Italy, 14-17 june, (2004).
- [MobiVIP, 2006] « *Rapport MobiVIP année 3, Véhicules Individuels Publics pour la Mobilité en centre ville, Plan d'expérimentation sur Biarritz* », projet Predit 3, par l'INRIA, Heudiasyc UMR CNRS/UTC, LASMEA UMR CNRS/UBP, L3I-Université de la Rochelle, CNRS I3S Projet Rainbow, 5 pages, décembre, (2006), disponible au 1^{er} août, (2008), sur : http://www.lasmea.univ-bpclermont.fr/ftp/pub/derutin/MobiVIP_final/D3_5.pdf.
- [Moral, 1993] P. Del Moral, J.-C. Noyer, G. Rigal, G. Salut, « *Traitemen non-linéaire du signal par réseau particulaire : Application radar* », In Actes Du 14^{ème} Colloque Gretsi sur Le Traitement Du Signal et Des Images, pp.399–402, Juan-les-Pins, France, 13-16 septembre, (1993).
- [Moral, 1994] P. Del Moral, « *Résolution particulaire des problèmes d'estimation et d'optimisation non-linéaires* », PhD thesis, Université Paul Sabatier, Toulouse, (1994).
- [Moral, 2004] P. Del Moral, « *Feynman-kac formulae genealogical and interacting particle systems with applications* », Probability and its Applications. Springer-Verlag, (2004).
- [Motamed, 2000] C. Motamed, « *Belief indicators in motion detection and tracking for video surveillance applications* », First IEEE Workshop on Performance Evaluation in Tracking and Surveillance, PETS'2000, pp 58-64,Grenoble, France, mars, (2000).

- [Murphy, 2002] K. P. Murphy, « *Dynamic bayesian networks: representation, inference and learning* », PhD thesis of University of California, Berkeley, fall, (2002).
- [Naim, 2004] P. Naim, P. H. Wuillemin, P. Leray, O. Pourret, A. Becker, « *Réseaux Bayésiens* », Groupe Eyrolles, ISBN : 2-212-11137-1, (2004).
- [Nackache, 2004] J.-P. Nackache, J. Confais, « *Approche pragmatique de la classification* », Edition TECHNIP, octobre, (2004).
- [Nguyen, 2007] V. Nguyen, S. Gätcher, A. Martinelli, N. Tomatis, R. Siegwart, « *A comparison of line extraction algorithms using range data for indoor mobile robotics* », Autonomous Robot 2007, Vol.23, pp.97-111 (2007).
- [Nordlund, 2002] P.-J. Nordlund, « *Sequential Monte Carlo Filters and Integrated Navigation* », PhD thesis, Linköping University, (2002).
- [Ouarab, 1999] N. Ouarab, Y. Smara, J.-P. Rasson, « *Utilisation de méthodes de classifications hiérarchique pour une classification supervisée d'images satellites* », Dix-septième colloque GRETSI, Vannes, septembre, (1999).
- [Pearl, 1986] J. Pearl, « *Fusion, Propagation, and Structuring in Belief Networks* », Artificial Intelligence 29, Elsevier Science Publishers B.V., (1986).
- [Pears, 2000] N. Pears, « *Feature extraction and tracking for scanning range sensors* », Robotics and Autonomous Systems, vol.33, pp.43–58 (2000).
- [Piel, 2007] G. Piel, « *Contribution à la mise en œuvre d'une plate-forme de simulation d'un système radar: application à un radar automobile d'aide à la conduite* », thèse de l'Ecole Nationale Supérieure des Télécommunications de Bretagne, mention « Physique et Sciences pour l'Ingénieur », n° d'ordre 2006telb0028, 223 pages, 23 janvier, (2007).
- [Premebida, 2005] C. Premebida, U. Nunes. « *Segmentation and geometric primitives extraction from 2D laser range data for mobile robot applications* », in Proc. of 4th Nat. Festival of Robotics Scientific Meeting (ROBOTICA'05), pp. 17-25, Coimbra, Portugal (2005).
- [PRE_URL] PREDIT (Programme de recherche et d'innovation dans les transports terrestres) site disponible au 1^{er} septembre, (2008), à l'URL <http://www.predit.prd.fr/predit3/menu.fo?cmd=predit>.
- [Quinlan, 1986] J. R. Quinlan, « *Induction of decision trees* », Machine Learning, 1, pp. 81-106, Kluwer Academic Publishers, Boston-Manufactured in the Netherlands, (1986).
- [Quinlan, 1993] J. R. Quinlan, « *C4.5:Programs for machine learning* », Morgan Kaufmann Publishers, (1993).
- [Reid, 1979] D. B. Reid, « *An Algorithm for Tracking Multiple Targets* », IEEE, Transaction on Automatic Control, Vol.24, No.6, december, (1979).
- [Rigo, 2004] M. Rigo, « *Gestion d'un système de perception (Télémètre et Stéréoscope) par intégration du contexte. Application au suivi d'objets* », Rapport de DEA, LASL-ULCO, juin, (2004).
- [Roumeliotis, 2000] S.I. Roumeliotis, G.A. Bekey, « *SEGMENTS: a Layered, dual Kalman filter algorithm for indoor feature extraction* », in Proc. of IEEE/RSJ Int. Conf. on Intelligent Robots and Systems, pp. 454-461 (2000).
- [Santos, 2003] Santos, S., J.E. Faria, F. Soares, R. Araujo, U. Nunes. « *Tracking of Multi-Obstacles with Laser Range Data for Autonomous Vehicles* », in Proc. of 3rd Nat. Festival of Robotics Scientific Meeting (ROBOTICA'03), pp. 59-65, Lisbonne, Portugal (2003).

- [SICK_URL] SICK Sensor Intelligence, <http://www.sick.de/home/en.html>, lien valide au 1er août, (2008).
- [Skolnik, 1990] M.I. Skolnik, « *Radar Handbook* », (2nd Edition), McGraw-Hill (1990).
- [Stephenson, 2000] Todd A. Stephenson, « An Introduction to Bayesian Network: Theory and Usage », IDIAP-RR, 00-03, February (2000).
- [Su, 2005] M.-C. Su, Y.-C. Liu, « *A new approach to clustering data with arbitrary shapes* », pattern recognition, 38(11), pp. 1887-1901, april, (2005).
- [Takizawa, 2004] H. Takizawa, K. Yamada, T. ITO, « *Vehicles detection using sensor fusion* », IEEE, Intelligent Vehicles Symposium, Pama, Italy, 14-17 June, (2004).
- [Trassoudaine, 1996] L. Trassoudaine, P. Checchin, J. Allizon, F. Collange, J. Gallice, « *Gestion intelligente de capteurs et fusion multisensorielle pour la détection et le suivi d'obstacles sur route* », Traitement du Signal, Vol. 13, No.2, pp. 127-142, (1996).
- [Trassoudaine, 2005] L. Trassoudaine, R. Chapuis, « *Intégration des fonctions « Anticollision » et « Gestion des inter-distances »* », ARCOS, Rapport interne, N° 04 MT 6002, décembre, (2005).
- [Vermaak, 2000] J. Vermaak, « *Bayesian Modelling and Enhancement of Speech Signals* », PhD thesis, University of Cambridge, (2000).
- [Wahl, 1997] Wahl, M., « *Contribution à la détection d'obstacles pour la voiture intelligente* », Thèse de Doctorat, Institut National Polytechnique de Grenoble, 5 décembre, (1997).
- [Wan, 2001] E. Wan, R. Van Der Merwe, « *Kalman Filtering and Neural Networks, chapter 7 - The unscented particle filter* », John Wiley, edited by simon haykin edition, (2001).
- [Welch, 2004] G. Welch, G. Bishop, « *An introduction to the Kalman filter* », University of North Carolina at Chapel Hill, Chapel Hill, NC 27599-3175, april, (2004).
- [Williams, 2003] Williams J.L., « *Gaussian mixture reduction for tracking multiple maneuver targets in clutter* », PhD thesis, AFIT/GE/ENG/03-19, march, (2003).
- [Williamson, 1999] T. Williamson, C. Thorpe, « *A trinocular stereo system for highway object detection* », IEEE, International Conference on Robotics and Automation, Detroit, Michigan, may, (1999).
- [Yguel, 2007] M. Yguel, O. Aycard, C. Laugier, « *Update Policy of Dense Maps: efficient algorithms and sparse representation* », 6th International Conference on Field and Service Robotics - FSR 2007 42, (2007).

Résumé

INTÉGRATION DU CONTEXTE PAR RÉSEAUX BAYÉSIENS POUR LA DÉTECTION ET LE SUIVI MULTI-CIBLES

Ces travaux se placent dans le cadre général de l'assistance au conducteur et plus particulièrement de la sécurité. L'objectif est ici de surveiller l'environnement d'un véhicule grâce à un capteur télémétrique à balayage et d'informer le conducteur de situations potentiellement dangereuses. Ce dispositif permet alors d'envisager une manœuvre d'évitement ou d'atténuation de collision. Deux points particuliers ont retenu notre attention : la détection d'objets qui occupe une place privilégiée car elle conditionne directement les performances globales de la méthode, et le processus d'association/suivi qui doit permettre d'associer efficacement les mesures disponibles à chaque objet suivi.

Les données télémétriques utilisées nécessitent de passer par une étape de détection afin d'estimer le nombre d'objets présents dans la scène et leur distance au capteur, en procédant à une agrégation des mesures liées au même objet. Nous proposons en particulier dans ce mémoire une méthode de détection d'objets qui exploite non seulement la nature des mesures disponibles mais également les caractéristiques géométriques particulières liées au contexte applicatif.

L'approche retenue pour l'étape d'association repose sur les méthodes d'association probabiliste de données qui permettent notamment de considérer le fait qu'une mesure disponible puisse ne pas être liée à un objet, en exploitant donc directement les notions de probabilité de détection et de fausse alarme. Ces probabilités, et notamment la probabilité de détection, demeurent non seulement fortement liées au détecteur, mais également au contexte de la scène : contexte capteur/objet et contexte objet/objet. Pour pouvoir intégrer ces informations globales de contexte, nous proposons une méthode d'association-suivi basée sur les réseaux bayésiens qui autorise l'intégration de paramètres liés aux caractéristiques des objets et du capteur dans la détermination de la probabilité de détection.

Mots-Clés : Perception, suivi d'objets, détection, filtrage statistique, réseaux bayésiens, approches PDA, JPDA, assistance à la conduite.

Abstract

CONTEXT INTEGRATION USING BAYESIAN NETWORKS FOR MULTITARGET DETECTION AND TRACKING

The general framework of this work concerns the driver assistance systems and more especially security. The objective here is to monitor the vehicle environment using a telemeter and inform the driver of potential hazardous situations. Maneuvers of collision avoidance or mitigation can then be considered. Two particular points have focused our attention: the object detection since it directly determines the overall performance of the method, and the association-tracking process which associates the available measurements to each tracked object.

The telemetric data must be processed, through a detection stage that aggregates the measurement from the same object, in order to estimate the number of objects in the scene and their distance to the sensor. We propose in this thesis a method for object detection that uses not only the available measurements but also the geometric characteristics related to the applicative context.

For the association stage, we particularly focus on the probabilistic data association methods that consider the available measure may not be linked to an object. These methods rely on the concept of detection and false alarm probabilities. These probabilities, and more particularly the probability of detection, are not only strongly linked to the detector, but also to the context of the scene (sensor / object and context object / object). To integrate the contextual information, we propose an association-tracking method based on the Bayesian networks. It allows an integration of the parameters related to the characteristics of the objects and the sensor in the determination of the detection probability.

Keywords: Perception, object tracking, detection, statistical filtering, Bayesian networks, PDA and JPDA approaches driver assistance.