



HAL
open science

Evaluation de situations dynamiques multicibles par fusion de données spatio-temporelles

Evangeline Pollard

► **To cite this version:**

Evangeline Pollard. Evaluation de situations dynamiques multicibles par fusion de données spatio-temporelles. Mathématiques [math]. Université Joseph-Fourier - Grenoble I, 2010. Français. NNT : . tel-00536071

HAL Id: tel-00536071

<https://theses.hal.science/tel-00536071>

Submitted on 15 Nov 2010

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

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

UNIVERSITÉ DE GRENOBLE
ÉCOLE DOCTORALE EEATS

T H È S E

pour obtenir le grade de

Docteur de l'Université de Grenoble

Spécialité : Signal, Image, Parole, Télécoms

préparé au GIPSA-lab

dans le cadre de l'**École doctorale EEATS**

Présentée et soutenue publiquement

par

Evangeline POLLARD

le 15 octobre 2010

**Évaluation de situations
dynamiques multicibles par fusion
de données spatio-temporelles**

Thèse dirigée par Michèle ROMBAUT
et Benjamin PANNETIER

Jury :

<i>Rapporteurs :</i>	CLAUDE JAUFFRET	Professeur	Université du Sud
	BRANKO RISTIC	Directeur de recherche	DSTO (Australie)
<i>Examineurs :</i>	ALAIN APPRIOU	Directeur de recherche	Onera
	ÉLOI BOSSÉ	Directeur de recherche	DRDC (Canada)
	FRÉDÉRIC DAMBREVILLE	Chercheur	DGA
<i>Directeur :</i>	MICHÈLE ROMBAUT	Professeur	GIPSA-lab Grenoble
<i>Co-Directeur :</i>	BENJAMIN PANNETIER	Chercheur	Onera

Résumé

Évaluation de situations dynamiques multicibles par fusion de données spatio-temporelles

Cette thèse, réalisée en coopération avec l'Onera, s'inscrit dans le domaine de la surveillance du champ de bataille. L'objectif des travaux est d'étudier et de développer une technique qui fusionne différentes sources d'informations, afin d'évaluer la situation tactique sur une large zone d'observation, ceci de manière semi-automatique en temps quasi-réel. Cette évaluation est réalisée en deux étapes. La première réalise une évaluation globale de la situation en utilisant une nouvelle technique de trajectographie (ou pistage) multicible par hybridation du filtre GM-CPHD et du MHT sous contrainte routière à partir des données GMTI (Ground Moving Target Indicator). Ce nouvel algorithme est adapté au pistage de cibles proches. Ensuite, la deuxième étape réalise une évaluation plus fine de la situation en détectant des objets dit d'intérêt tels que des convois par l'intégration d'autres types de données (SAR, vidéo). La détection se base sur l'utilisation des réseaux bayésiens ainsi que leur version crédibiliste.

Mots clés : Évaluation de situation, pistage multicible, détection d'objet d'intérêt, convoi, filtre GM-CPHD, réseaux bayésiens, réseaux crédibilistes, modèle des croyances transférables

Abstract

Multi-target situation assessment by data fusion of spatial-temporal data.

This PhD work, carried out in collaboration with Onera, is in the domain of battlefield surveillance. The goal is to develop multi-source data fusion approaches for wide area situation assessment, the approaches being semi-automatic almost real time. The two-step method, developed for the situation assessment, consists of two granularity levels. The first step is a global situation evaluation using a new multitarget tracking algorithm, a hybridization of two existing algorithms : the GM-CPHD filter and the MHT with road constraints. This algorithm, which uses GMTI data, can be applied to resolved targets as well as closely spaced targets. A more accurate situation assessment is done in a second step, by detecting objects of interest such as convoys by using other data types (SAR, video). These detections are based on Bayesian networks, as well as their credibilistic counterpart.

Key words : Situation assessment, Multitarget tracking, object of interest detection, convoy, GM-PCHD filter, Bayesian network, credibilist network, Transferable Belief Model

Remerciements

Je tiens tout d'abord à remercier l'ensemble des membres de mon jury et tout particulièrement mes rapporteurs : Claude Jauffret et Branko Ristic. J'imagine tout le travail qu'a représenté pour eux la lecture attentive de ce manuscrit. Merci pour leurs suggestions d'améliorations constructives. Mes remerciements vont également à Alain Appriou, président du jury ainsi qu'à Éloi Bossé, qui s'est déplacé de loin (Québec) et à Frédéric Dambreville.

Il me faut également remercier avec beaucoup de sincérité mes encadrants de thèse, Michèle Rombaut et Benjamin Pannetier, qui m'ont accompagnée durant ces trois années. Un grand merci à Michèle pour son regard bienveillant, sa rigueur scientifique, son intégrité et le goût pour la recherche qu'elle m'a transmis. Toute ma reconnaissance à Benjamin pour ses qualités humaines et scientifiques.

Mes remerciements s'adressent maintenant à l'ensemble de mes collègues : ils ont tous permis le développement d'un environnement de travail agréable et stimulant pour cette thèse. Je remercie bien sûr Gilles Foulon, pour m'avoir accueillie dans son département. Je remercie Françoise Pradines, qui outre ses compétences secrétaires, m'a toujours témoigné une profonde amitié. Je remercie tout particulièrement Martial Sanfourche et Aurélien Plyer, qui m'ont volontiers aidé en toutes circonstances, quels que soient les (hauts) défis informatique ou \LaTeX que je leur lance. Je remercie mes relecteurs de thèse : Bertrand Le Saux (Monsieur Dictionnaire, merci pour tous les mots que tu m'as appris!) et Fabrice Janez (préviens moi quand tu ouvriras un restaurant). Merci aux nouvelles filles du DTIM : Valérie Leung (merci pour tous nos échanges en anglais et en français), Valentina Dragos, Laure Genin et Pauline Trouvé : continuez à recruter des filles ! Merci aussi à celles qui étaient là avant moi : Annie Bastière et Kaoutar Benameur.

Un merci particulier à nos deux organisateurs : de pots (Joseph Defretin) et de sorties ciné (Guillaume Roussel), vous savez à quel point je trouve important de se voir dans un contexte plus détendu. Un merci particulier également à Fabrice Savignol, j'espère que le temps qui passe le verra toujours aussi pétillant de vie (et merci pour toutes les tartes qu'il m'a remontées de la cantine. Résultat des courses : pas pris un kilo en trois ans!). Je remercie Jean Dezert, que j'ai eu grand plaisir à cotoyer à l'occasion de différents congrès. Je terminerai avec les habitués de la salle café. Je remercie donc Guy Le Besnerais, Stéphane Herbin, Philippe Cornic, Frédéric Champagnat (je m'en souviendrais de tes probas!), Patrick Secchi, Christophe Guilmart, Olivier Poirel : j'ai eu beaucoup de plaisirs à discuter avec vous. J'ai failli oublier de remercier Jérôme Besombes, à qui je dois la qualité graphique des schémas de cette thèse, mais pas que !

J'ai bien entendu une pensée pour les anciens : Marie-Lyse Duplaquet, Adrien Revault D'Allonnes, Jonathan Guinet, Antoine Letienne et Anne-Marie Tusch. J'espère que nous aurons l'occasion de nous recroiser.

En dernier lieu, je souhaite remercier l'ensemble de mes proches, qui ont partagé avec moi les moments heureux et les moments difficiles rencontrés durant ces trois années.

Table des matières

Liste des notations mathématiques	xiii
Liste des notations	xv
Liste des abréviations	xxv
0 Introduction	1
1 Évaluation de situations : état de l’art et analyse de la problématique	5
1.1 Hiérarchisation des niveaux de fusion	7
1.1.1 Contexte	7
1.1.2 Les avantages de la fusion multicapteur	8
1.1.3 Applications	9
1.1.4 Architecture de fusion de données	9
1.1.5 Le Joint Directors of Laboratories	9
1.2 Analyse du problème	11
1.2.1 Définition d’un objet d’intérêt	12
1.2.2 Définition d’un convoi	13
1.2.3 Description des données	14
1.2.4 Bilan	19
1.3 Différentes approches pour traiter l’information	20
1.3.1 La théorie probabiliste	20
1.3.2 La théorie possibiliste	22
1.3.3 La théorie crédibiliste	24
1.3.4 Le conditionnement	30
1.3.5 Comparaison des différentes méthodes	33
1.4 Pistage multicible	35
1.4.1 Synthèse du problème d’estimation	35
1.4.2 Modélisation d’une cible	35
1.4.3 Les enjeux du pistage multicible	36
1.4.4 Le filtre PHD	40
1.4.5 Le filtrage particulière	44
1.4.6 Les méthodes de type Kalman	49
1.4.7 Comparaison des différentes méthodes	56
1.5 Différentes approches pour représenter un système	58
1.5.1 Les graphes	58
1.5.2 Les automates	58
1.5.3 Les gabarits	60
1.5.4 Les réseaux bayésiens	61
1.5.5 Les modèles de Markov cachés	62
1.5.6 Les réseaux de neurones	63
1.5.7 Les réseaux de Petri	63
1.5.8 Les chroniques	64
1.5.9 Comparaison des différentes méthodes	64

I	Pistage multicible adapté au pistage de cibles proches	67
2	Hybridation des algorithmes PHD et MHT	69
2.1	Comparaison des algorithmes de pistage multicible existants	70
2.2	Création d'un algorithme hybride CPHD et MHT	73
2.2.1	Hybridation du filtre CPHD et du MHT	73
2.3	Implémentation du filtre CPHD par mélange de gaussiennes	76
2.3.1	Le théorème des sommes gaussiennes	76
2.3.2	Les hypothèses de modèles gaussiens	76
2.3.3	Le filtre GM-CPHD	77
2.3.4	Équations de prédiction	77
2.3.5	Équations de mise à jour	78
2.3.6	Implémentation	79
2.3.7	L'évaluation du nombre de cibles	80
2.4	Labellisation du filtre CPHD	81
2.4.1	Problématique	81
2.4.2	Approches existantes pour la labellisation	82
2.4.3	Matrice d'association	83
2.4.4	Poids global d'une association	86
2.4.5	La matrice de coût	87
2.5	Optimisation de l'algorithme de labellisation	88
3	Amélioration des performances de pistage	93
3.1	Introduction des coordonnées des routes pour l'estimation des pistes	94
3.1.1	Projection des cibles sur un segment de route	94
3.1.2	Projection des cibles sur l'ensemble du réseau routier	97
3.1.3	IMM avec contraintes à structure variable	100
3.1.4	Algorithme hybride avec les coordonnées des routes	102
3.2	Introduction du type des cibles	103
3.2.1	Pistage avec le MHT sous contrainte et l'information de type.	103
3.2.2	Pistage avec le GM-CPHD et l'information de type.	105
3.3	Utilisation des masques de terrain	106
II	Fusion de données pour la détection d'objets d'intérêt	109
4	Un modèle de Réseau Bayésien pour la détection de convoi	111
4.1	Traitement des agrégats	112
4.1.1	Détection des agrégats	113
4.1.2	Caractéristiques d'un convoi extraites à partir d'un agrégat	114
4.2	Sélection des techniques pour la détection de convois	115
4.2.1	Rappels sur la problématique de détection de convois	116
4.2.2	Choix d'une méthode de représentation du système	116
4.2.3	Choix d'une méthode pour traiter l'information	117
4.3	Modélisation de convois par les réseaux bayésiens	117
4.4	Calcul des probabilités	119
4.4.1	Vitesse inférieure à une vitesse maximum	119
4.4.2	Vitesse constante	122

4.4.3	Critère vitesse	122
4.4.4	Évolution sur la route	123
4.4.5	Véhicules de type militaire	123
4.4.6	Longueur du convoi constante	123
4.4.7	Distance constante entre les cibles	123
4.4.8	Critère distance	124
4.4.9	convoi	124
4.4.10	Bilan	125
4.5	Expertise des probabilités conditionnelles	125
4.5.1	Composition du réseau	125
4.5.2	Établissement des probabilités conditionnelles	126
4.6	Estimation du nombre de cibles	129
4.6.1	Cas où il y a au plus un seul agrégat à chaque itération	129
4.6.2	Cas où il y a plusieurs convois	133
5	Les réseaux crédibilistes : prise en compte du conflit	137
5.1	Réseaux bayésiens <i>vs.</i> crédibilistes	138
5.1.1	Généralités sur les modèles graphiques	138
5.1.2	De l'intérêt d'utiliser les fonctions de croyance	138
5.2	Réseaux crédibilistes	140
5.2.1	Description du mécanisme d'inférence	140
5.2.2	Application à la détection de convoi	141
5.3	Réseau crédibiliste dynamique	144
5.3.1	Filtre temporel crédibiliste	144
5.3.2	Application à la détection de convois	145
5.4	Implémentation du réseau crédibiliste	146
5.4.1	Transformation des données en masse de croyance	146
5.4.2	Prise en compte de la direction de déplacement des cibles	146
5.4.3	Estimation du nombre de cibles évoluant dans le sens de l'agrégat	147
III	Résultats	153
6	Mesures de performance pour le pistage	155
6.1	Mesures de performance globale	156
6.1.1	Mesures calculées à chaque itération	156
6.1.2	Mesures moyennées sur le temps	156
6.2	Performances individuelles	157
6.3	Les nouvelles métriques	158
6.3.1	Distance de Wasserstein	159
6.3.2	Distance OSPA (Optimal SubPattern Assignment)	163
6.3.3	Un cas d'école	164
7	Résultats sur données simulées	167
7.1	Paramètres de simulation	168
7.1.1	Paramètres du capteur GMTI	168
7.1.2	Paramètres du filtre GM-CPHD	168
7.1.3	Paramètres de l'IMM-MHT	169

7.1.4	Paramètres de l'hybridation	169
7.1.5	Paramètres de détection de l'agrégat	170
7.1.6	Paramètres de transformation des données en probabilités	170
7.1.7	Paramètres de calcul des MOP	172
7.2	Scénario 1 : basique	173
7.2.1	Description du scénario 1	173
7.2.2	Résultats du scénario 1	175
7.3	Scénario 2 : dépassement d'un convoi	185
7.3.1	Résultats du pistage pour le scénario 2	185
7.3.2	Résultats pour la détection de convois pour le scénario 2	194
7.3.3	Bilan	196
7.4	Scénario 3 : complexe	198
7.4.1	Description du scénario 3	198
7.4.2	Résultats du scénario 3 pour la détection de convois	200
7.4.3	Résultats pour la détection de convois pour le scénario 3	211
7.4.4	Bilan sur le scénario 3	216
7.5	Scénario 4 : manœuvre intrinsèque dans un convoi	219
7.5.1	Description du scénario 4	219
7.5.2	Résultat du pistage	221
7.5.3	Résultat pour la détection de convoi	222
7.6	Influence des paramètres	226
7.6.1	Nombre de cibles dans le convoi	226
7.6.2	Distance entre les cibles	227
7.6.3	Densité de fausses alarmes	229
7.6.4	Bruit de mesures	230
7.6.5	Paramètres de transformation des données en probabilités	231
7.6.6	Paramètres d'estimation du nombre de cibles	232
8	Résultats sur données réelles	235
9	Conclusion générale et perspectives	237
A	Les réseaux bayésiens	241
A.1	Généralités sur les réseaux bayésiens	242
A.1.1	Introduction	242
A.1.2	Définition	242
A.1.3	Structure	242
A.1.4	La d-séparation : définition et propriété	243
A.1.5	Construction d'un réseau bayésien et apprentissage	244
A.2	Inférence bayésienne	245
A.2.1	L'algorithme JLO	245
A.2.2	L'algorithme EM	247
A.3	Les réseaux bayésiens dynamiques	248
A.4	Les modèles de Markov cachés	249
A.4.1	Les chaînes de Markov du 1 ordre	249
A.4.2	Les modèles de Markov cachés	249
A.4.3	Applications possibles pour les HMM	250

Bibliographie	253
Liste des publications	265

Table des figures

1	Processus de détection de convois	3
1.1	Un système de fusion de données : le cerveau humain	7
1.2	Illustration de l'utilité de la fusion de données homogènes	8
1.3	Différentes architectures de traitement	10
1.4	Schéma de principe du JDL	10
1.5	Représentation du repère cartésien local et du repère géocentré	15
1.6	Cumul des plots MTI	18
1.7	Exemple de DTED	19
1.8	Multi-causalité entre A et B	21
1.9	Sous-ensembles flous représentés par des triangles et des trapèzes	23
1.10	Opérateur adaptatif	24
1.11	Représentation graphique des probabilités sur Ω	26
1.12	Représentation graphique classique des masses de croyances sur 2^Ω	26
1.13	Représentation graphique des ensembles Ω	26
1.14	Nouvelle représentation graphique des masses de croyance sur 2^Ω	26
1.15	Illustration du calcul de $m^\Omega(\omega_1)$ à partir des plausibilités	28
1.16	Illustration du calcul de $m^\Omega(\omega_{12})$ à partir des plausibilités	28
1.17	Illustration du calcul de $m^\Omega(\omega_{12})$ à partir des crédibilités	29
1.18	Illustration des différentes fonctions élémentaires	29
1.19	Représentation graphique du conditionnement	30
1.20	Causalité entre deux variables	32
1.21	Schéma bloc du problème d'estimation	35
1.22	Scénario problématique d'association	37
1.23	Différents estimateurs d'état	38
1.24	Évolution de la fonction d'intensité de $k - 1$ à k	40
1.25	Illustration du problème de non gaussianité de mesures proches	44
1.26	Illustration du filtrage particulaire classique	45
1.27	Un exemple de clustering avec le k -means	47
1.28	Arbre d'hypothèses du MHT	51
1.29	Schéma bloc du MHT	53
1.30	Un exemple de graphe non-orienté simple	59
1.31	Un exemple de graphe complexe	59
1.32	Un automate déterministe	59
1.33	Un automate non-déterministe	59
1.34	Un exemple de gabarit	60
1.35	Un exemple de réseau bayésien	61
1.36	La problématique du filtrage de Kalman vue sous la forme d'un HMM	62
1.37	Un exemple de réseaux de Petri	63
2.1	Ensemble des plots MTI à deux itérations successives	71
2.2	Hybridation IMM-MHT / GM-CPHD	74
2.3	Problème de labellisation du filtre CPHD	82

2.4	Un exemple de labellisation pour le filtre GM-CPHD	84
2.5	Schéma fonctionnel de la labellisation du GM-CPHD	91
3.1	Orientation de l'écart-type associé au bruit de modèle	95
3.2	Projection optimisée de l'état estimé	96
3.3	Étape de prédiction sur un réseau routier	98
3.4	Étape d'estimation sur un réseau routier	100
3.5	Prise de décision différée dans le cas d'intersection	101
3.6	Les trois modèles dynamiques génériques	101
3.7	Synoptique du VS-IMMC pour deux modèles	102
3.8	Hybridation du filtre GM-CPHD et du VS-IMMC-MHT	103
3.9	Illustration des améliorations apportées par le type	104
3.10	Scénario problématique d'association	105
3.11	Masque de terrain	106
4.1	Processus de détection de convois	112
4.2	Exemple d'agrégat	113
4.3	Positionnement des gaussiennes et des mesures	115
4.4	Modélisation d'un convoi par les réseaux bayésiens	118
4.5	Probabilité que v soit inférieure/supérieure à v_{max}	121
4.6	Variations de la probabilité de S_2	122
4.7	Variations de la probabilité de S_7	124
4.8	Décomposabilité du réseau	126
4.9	Choix des N_i^C cibles parmi les N^{A_k} cibles de l'agrégat	131
4.10	$P\{S_9^k N_{k_0:k}^A, N_i^C\}$: probabilité qu'un agrégat soit un convoi sachant N_i^C	132
5.1	Modèle graphique représentant un cas de diagnostic médical	139
5.2	Un exemple basique de réseau crédibiliste	140
5.3	Décomposition du réseau crédibiliste	142
5.4	Principe du filtre temporel crédibiliste	144
5.5	Opérateur de transformation d'une distribution de probabilité en masses	146
5.6	Un deuxième modèle pour la modélisation de convois.	147
5.7	Opérations pour calculer le nombre de cibles évoluant dans le même sens	149
5.8	Étude des cas limites	150
6.1	Illustration du problème de calcul de performances dans un cas multicible	159
6.2	Cas très défavorable pour le calcul de la distance de Wasserstein	161
6.3	Un cas d'école	165
7.1	Choix des paramètres des réseaux bayésiens	172
7.2	Trajectoire des cibles du scénario 1	173
7.3	Scénario 1	174
7.4	Cumul des plots MTI du scénario 1	174
7.5	Ratio de longueur des pistes	175
7.6	RMSE position	176
7.7	RMSE vitesse	177
7.8	Complétude, ratio de fausses pistes, ratio de pistes redondantes	177
7.9	Continuité de pistage de la cible 1	178

7.10	RMSE position et vitesse de la cible 1	179
7.11	Continuité de pistage de la cible 2	179
7.12	RMSE position et vitesse de la cible 2	180
7.13	Continuité de pistage de la cible 3	180
7.14	RMSE position et vitesse de la cible 3	181
7.15	Continuité de pistage de la cible 6	181
7.16	RMSE position et vitesse de la cible 6	182
7.17	Continuité de pistage de la cible 9	182
7.18	RMSE position et vitesse de la cible 9	183
7.19	Cardinalité, distance de Wasserstein et OSPA	183
7.20	Trajectoire des cibles du scénario 2	185
7.21	Scénario 2	186
7.22	Cumul des plots MTI du scénario 2	186
7.23	Ratio de longueur des pistes	187
7.24	RMSE position	188
7.25	RMSE vitesse	188
7.26	Complétude, ratio de fausses pistes, ratio de pistes redondantes	189
7.27	Continuité de pistage de la cible 1	190
7.28	RMSE position et vitesse de la cible 1	190
7.29	Continuité de pistage de la cible 2	191
7.30	RMSE position et vitesse de la cible 2	191
7.31	Continuité de pistage de la cible 3	192
7.32	RMSE position et vitesse de la cible 3	192
7.33	Continuité de pistage de la cible 4	193
7.34	RMSE position et vitesse de la cible 4	193
7.35	Distances de Wasserstein et OSPA pour le scénario 2	194
7.36	Probabilité de détection de convoi avec la vérité terrain	195
7.37	Probabilité de détection du convoi 1	196
7.38	Probabilité de détection du convoi 1 de taille N^C	197
7.39	Probabilité de détection du convoi 1 de taille N^C connaissant $N_{k_0 k}^A$	197
7.40	Trajectoire des cibles du scénario 3	198
7.41	Scénario 3	199
7.42	Cumul des plots MTI du scénario 3	200
7.43	RMSE position	201
7.44	RMSE vitesse	201
7.45	Ratio de longueur des pistes	202
7.46	Complétude, ratio de fausses pistes, ratio de pistes redondantes	202
7.47	Continuité de pistage de la cible 1	203
7.48	RMSE position et vitesse de la cible 1	203
7.49	Continuité de pistage de la cible 2	204
7.50	RMSE position et vitesse de la cible 2	204
7.51	Continuité de pistage de la cible 3	205
7.52	RMSE position et vitesse de la cible 3	205
7.53	Continuité de pistage de la cible 9	206
7.54	RMSE position et vitesse de la cible 9	207
7.55	Continuité de pistage de la cible 13	208
7.56	RMSE position et vitesse de la cible 13	208

7.57	Continuité de pistage de la cible 14	209
7.58	RMSE position et vitesse de la cible 14	209
7.59	Cardinalité, distance de Wasserstein et OSPA	210
7.60	Probabilité pour la variable S_9 : $P\{S_9^k\}$	212
7.61	Masse de croyance pour la variable S_9 avec le modèle bis : $\tilde{m}_k^{\Omega_9}$	212
7.62	Masse de croyance estimée pour la variable S_9 avec le modèle bis : $\hat{m}_k^{\Omega_9}$	213
7.63	Masse de croyance estimée pour la variable S_9 avec le modèle bis : \hat{m}_k^\emptyset	213
7.64	Masse de croyance estimée pour la variable S_3 avec le modèle bis : $\hat{m}_k^{\Omega_3}$	214
7.65	Masse de croyance estimée pour les variable S_4 et S_8 :	214
7.66	Masse de croyance estimée pour la variable S_9 avec le modèle bis : \hat{m}_k^\emptyset	215
7.67	Masse de croyance pour la variable S_9 avec le modèle bis	215
7.68	Probabilité pour la variable S_9 : $P\{S_9^k\}$	216
7.69	Masse de croyance pour la variable S_9 avec le modèle bis : $\tilde{m}_k^{\Omega_9}$	217
7.70	Masse de croyance estimée pour la variable S_9 avec le modèle bis : $\hat{m}_k^{\Omega_9}$	217
7.71	Masse de croyance estimée pour la variable S_9 avec le modèle bis : \hat{m}_k^\emptyset	218
7.72	Trajectoire des cibles du scénario 4	219
7.73	Scénario 4	220
7.74	Cumul des plots MTI du scénario 4	220
7.75	Cardinalité, distance de Wasserstein et OSPA	221
7.76	Probabilité pour la variable S_9 : $P\{S_9^k\}$	222
7.77	Masse de croyance estimée pour la variable S_9 avec le modèle bis : $\hat{m}_k^{\Omega_9}$	223
7.78	Masse de croyance estimée pour la variable S_3 avec le modèle bis : $\hat{m}_k^{\Omega_3}$	223
7.79	Masse de croyance du conflit pour la variable S_9 avec le modèle bis : $\hat{m}_k^{\Omega_9}(\emptyset)$	223
7.80	Masse de croyance estimée pour la variable S_8 avec le modèle bis : $\hat{m}_k^{\Omega_8}$	224
7.81	Zoom sur la séparation du convoi	225
7.82	Performances en fonction du nombre de cibles	226
7.83	Performances en fonction de la distance entre les cibles	228
7.84	Performances en fonction de la densité de fausses alarmes	229
7.85	Performances en fonction du bruit de mesure	230
7.86	Probabilité d'avoir un convoi avec le jeux de paramètres 1	231
7.87	Probabilité d'avoir un convoi avec le jeux de paramètres 2	232
7.88	Probabilité de détection du convoi 1 de taille N^C	233
7.89	Principe général de l'hybridation	234
9.1	Schéma du processus de détection de convoi	239
9.2	Schéma du processus de détection d'objets d'intérêt	240
A.1	Linéaire	243
A.2	Divergente	243
A.3	Convergente	243
A.4	Un exemple de réseau bayésien avec 5 variables	243
A.5	Transformation du réseau bayésien	246
A.6	Un exemple de réseau bayésien dynamique	248
A.7	Illustration des notations du HMM	250

Liste des tableaux

1.1	Un exemple de transformation d'une distribution de masses	28
1.2	Avantages et inconvénients des représentations de l'incertain	34
1.3	Avantages et inconvénients des techniques de pistage existantes	57
1.4	Avantages et inconvénients des représentations symboliques d'informations	65
2.1	Hybridation du filtre CPHD et du MHT	73
4.1	Récapitulatif des paramètres pour la mise en œuvre des réseaux bayésiens	125
4.2	Tableau des probabilités conditionnelles de S_9	127
4.3	Tableau des probabilités conditionnelles de S_3	128
4.4	Tableau des probabilités conditionnelles de S_3	128
4.5	Tableau des probabilités conditionnelles de S_8	129
4.6	Tableau des probabilités conditionnelles de S_5	129
7.1	Paramètres du capteur GMTI	169
7.2	Paramètres du filtre GM-CPHD	169
7.3	Paramètres du filtre MHT	170
7.4	Paramètres du filtre IMM	170
7.5	Paramètres de l'hybridation	170
7.6	Récapitulatif des paramètres pour la mise en œuvre des réseaux bayésiens	171
7.7	Récapitulatif des paramètres pour la mise en œuvre des réseaux bayésiens	171
7.8	Paramètres de calcul des MOP	172
7.9	Dynamique des cibles du scénario 1	173
7.10	Dynamique des cibles du scénario 2	185
7.11	Dynamique des cibles du scénario 3	199
7.12	Dynamique des cibles du scénario 4	219
7.13	Jeu de paramètres 2 pour la mise en œuvre des réseaux bayésiens	231

Liste des notations mathématiques

$\mathbb{E}[\cdot]$	Espérance d'une variable	16
A^T	Transposée de la matrice A	39
$P\{\cdot\}$	Probabilité	20
$d(a, b)$	Distance euclidienne entre a et b	98
$\text{int}(a, b)$	Intersection entre a et b	98
e_j	Fonction symétrique élémentaire	43
C_j^l	Coefficient binomial de paramètre (j, l) où $j \leq l$	42
P_{j+u}^n	Coefficient de permutation de paramètres $(j + u, n)$	78
$ \cdot $	Cardinalité	40
$x \rightarrow s$	Projection de x sur le segment s	96
δ	Distribution de Dirac	98
$\ \cdot\ _p$	Norme de dimension p	160
$d^p(\mathbf{x}, \mathbf{y})$	Distance au sens de la norme \mathcal{L}^p	160

Liste des notations

\mathbf{A}_k	Matrice binaire d'association optimale des gaussiennes aux pistes à l'itération k	83
A_k	Ensemble des matrices d'association possibles entre les gaussiennes et les pistes à l'itération k	84
$A_{k,a}$	Matrices a d'association possible entre les gaussiennes et les pistes à l'itération k	84
\tilde{A}_k	Matrice d'association globale des gaussiennes aux pistes à l'itération k	85
A_k^*	Ensemble des matrices d'association qui maximisent le poids global ...	87
A^{MHT}	Matrice d'association du MHT	50
\mathcal{A}_k	Un agrégat à l'itération k	113
b_k	Bruit de mesure sur les composantes x, y à l'itération k	16
$B_{k k-1}(\zeta)$	RFS des cibles non résolues issues des états précédents ζ à l'itération $k - 1$	40
$bel^\Omega(A)$	Crédibilité d'un élément A	27
$b^\Omega(A)$	Implicabilité d'un élément A	27
$\text{BetP}_m(\omega_k)$	Probabilité pignistique de l'hypothèse ω_k	32
$c_{k,i}$	Booléen indiquant si un objet est de type militaire ou non	17
C_k	Matrice de coût à l'itération k	87
$C_{k,a}^{\}$	Coût global de l'association a à l'itération k	88
c	Coût d'une association	87
C^i	Matrice de confusion pour la classification	17
(c, p)	Paramètres de calcul de la distance OSPA	163
$\bar{d}_p^{(c)}(\mathbf{x}, \mathbf{y})$	Distance OSPA entre \mathbf{x} et \mathbf{y} de paramètres (c, p)	163
$d^{(c)}(x, y)$	Distance minimale entre la distance effective entre x et y et une distance maximale	163
\tilde{D}	Matrice de contrainte de projection optimisée	97
$d_p^W(\mathbf{x}, \mathbf{y})$	Distance de Wasserstein entre les ensembles \mathbf{x} et \mathbf{y} au sens de la norme \mathcal{L}^p	160

e_k^s	Évènement que la cible x_k évolue sur le segment s à l'itération k	96
$e_{k,i}^{pos}$	Erreur quadratique moyenne en position associée à la cible i à l'itération k 157	
$e_{k,i}^{vit}$	Erreur quadratique moyenne en vitesse associée à la cible i à l'itération k 157	
$f_{k+1 k}(X_{k+1} X_k)$	Densité de transition d'un état $k + 1$ à k multicible	38
$f(x_{k+1} \mathbf{Z}^k)$	Densité de probabilité <i>a priori</i>	39
$f(x_{k+1} Z^{k+1})$	Densité de probabilité <i>a posteriori</i>	39
F_k	Matrice de transition de l'état $k - 1$ à l'état k	35
$F_{k,l}^s$	Matrice de transition de l'état selon le modèle dynamique l sous le contrainte du segment s de l'état $k - 1$ à l'état k	95
σ_x, σ_y	Écart-type en x et y	36
ν_k	Bruit d'état	36
Γ_k	Matrice de transition du bruit de modèle	35
$g(z_{k+1} \mathbf{Z}^k)$	Fonction de vraisemblance	39
$\pi_{k+1 k}(X_{k+1} \mathbf{Z}^k)$	Densité de probabilité jointe <i>a priori</i>	38
$\pi_{k+1}(X_{k+1} Z^{k+1})$	Densité de probabilité jointe <i>a posteriori</i>	38
$g_{k+1}(Z_{k+1} X_{k+1})$	Fonction de vraisemblance multicible	38
$\pi_{k+1 k}(x_{k+1} x_k)$	Densité de transition d'un état $k + 1$ à k	39
σ_k	RFS modélisant les cibles naissantes à l'itération k	40
Θ_k	Ensemble des scénarios d'associations à l'itération k	55
Θ_k^a	Scénarios d'associations a à l'itération k	55
Ω_k	Matrice de validation à l'itération k	55
$\hat{\Omega}_k^a$	Matrice d'associations a à l'itération k	55
$\Upsilon_k^0[v_k _{k-1}, Z_k](n)$	Vraisemblance du jeu de mesures par rapport à la fonction d'intensité prédite sachant qu'il y a n cibles et qu'elles peuvent toutes être détectées	43
$\Upsilon_k^1[v_k _{k-1}, Z_k]$	Vraisemblance du jeu de mesures par rapport à la fonction d'intensité prédite sachant qu'il y a n cibles et que au moins l'une d'elle est non détectée	43
$g(z x)$	Vraisemblance d'une mesure z connaissant l'état d'une cible x	41

κ_k	Fonction d'intensité du bruit	41
$\beta_{k,j}^{(i)}$	Poids accordé à l'association de la mesure i avec la cible j	54
γ	Seuil de fenêtrage	49
γ_1	Seuil de confirmation de piste	53
γ_2	Seuil de suppression de piste	53
β_{fa}	Densité de fausses alarmes	16
β_{nt}	Densité de probabilité de cibles naissantes	75
Δ	Période d'échantillonnage du capteur GMTI	16
θ_s	Angle formé par le segment routier s dans le repère cartésien local	95
$\mathcal{G}_{k,j}$	La gaussienne j à l'itération k	82
$\nu_{k,l}^s$	Bruit de mesure contraint au segment routier s	95
ξ_k	Ensemble de segments routiers sur lequel l'état estimé $\hat{x}_{k k}$ peut être projeté à l'itération k	99
$g(\mathcal{G}_{k,n} \hat{x}_{k k-1,j})$	Vraisemblance de la gaussienne $\mathcal{G}_{k,n}$ par rapport à la position prédite de la piste $\hat{x}_{k k-1,j}$	88
$g^{\mathcal{J}}(\mathcal{G}_{k,n} \hat{x}_{k k-1,j})$	Vraisemblance $g(\mathcal{G}_{k,n} \hat{x}_{k k-1,j})$ avec prise en compte de l'information type 105	105
$\nu_{k,j}$	Bruit de mesure	53
Ω_A	Espace fini de l'évènement A	53
$\gamma_k(x)$	Fonction d'intensité de naissance des cible	77
μ_i	Fonction d'appartenance à une classe i	23
$\Pi_d(i)$	Mesure de possibilité de la mesure d à la classe i	23
ω_{ij}	Union des hypothèses ω_i et ω_j	25
2^Ω	Cadre de discernement crédibiliste	25
\mathcal{G}_k	Ensemble des gaussiennes à l'itération k	82
$\iota_{k,i}^n$	Continuité de pistage de la cible i à l'itération k pour le jeu de mesure n	158
$\bar{\iota}_{k,i}^n$	Taux de changement de piste de la cible i à l'itération k pour le jeu de mesure n	158
Π	Ensemble d'association d'un ensemble à un autre	163

α^A	Distance seuil considérée entre deux cibles pour qu'elles forment un agrégat 113
$\alpha^{\mathcal{L}}$	Épaisseur de la ZOI réduite entourant un agrégat114
H	Matrice de transition de l'espaces d'état vers l'espace des mesures16
h_{12}	Mesure du degré de compatibilité de deux sources 23
\mathfrak{J}	Ensemble des attributs d'identité fourni par un capteur GMTI 16
i^a	Un attribut a d'identité parmi l'ensemble \mathfrak{J}16
$i_{k,i}$	Identité de la cible i à l'itération k17
\mathcal{I}^A	Liste ordonnée des indice des cibles d'un agrégat \mathcal{A} 114
J_{max}	Nombre maximal de gaussiennes considérées pour le GM-CPHD 169
K_k	RFS des fausses alarmes à l'itération k 40
k	numéro de l'itération 16
$\mathcal{L}(Z_k)$	Vraisemblance d'un ensemble de mesures Z_k à l'itération k42
L	Vecteur de contrainte de projection optimisée97
$\mathcal{L}(Z_k n)$	Vraisemblance du jeu de mesures sachant qu'il y a n cibles42
\mathcal{L}^2	Norme de dimension 2159
\mathcal{L}^p	Norme de dimension p159
\mathcal{L}^∞	Norme de dimension infinie159
\mathcal{L}^A	Longueur d'un agrégat \mathcal{A}114
$m_{k,j}$	Nombre de mesures appartenant à la fenêtre de validation de la cible j à l'itération k 49
m_k	Nombre de mesures à l'itération k 15
$m_{k,j}^{\mathcal{G}}$	Position de la gaussienne i à l'itération k 82
$m^{PCR5}(\omega)$	Masse combinée de ω issue de la PCR5105
m^Ω	Masse de croyance sur l'ensemble des hypothèses Ω 25
$m_1^\Omega \circledast_2(A)$	Masse combinée des sources 1 et 2 sur l'hypothèse A selon la CRC30
$m_1^\Omega \odot_2(A)$	Masse combinée des sources 1 et 2 sur l'hypothèse A selon la DRC31
αm^Ω	Masse de croyance affaiblie par le coefficient α32

$m^\Theta[\omega](\theta)$	Masse de croyance de l'hypothèse θ calculée sur l'ensemble Θ conditionnellement à ω	32
$m_{k,i}^\gamma$	Position de la gaussienne i correspondant à une cible naissante à l'itération k	77
N_{fa}	Nombre moyen de fausses alarmes à chaque itération	16
N_k	Nombre réel de cibles à l'itération k	37
$\hat{N}_{k k}$	Nombre estimé de cibles à l'itération k	18
$N_k^{\mathcal{G}}$	Nombre de gaussiennes caractérisant l'intensité $v_{k k}$ à l'itération k	82
N_a	Nombre de combinaisons d'associations possibles entre les gaussiennes et les pistes	84
$N_k^{\mathcal{G}}$	Nombre de gaussiennes à l'itération k	86
N^s	Nombre de segments à parcourir	97
N^p	Nombre de particules	45
N_{MC}	Nombre de jeux de Monte-Carlo	157
$N_{k,i}^{MC}$	Nombre de jeux de Monte-Carlo à l'itération k où la cible i est associée à une piste	157
N_{max}	Nombre maximal de cibles considérés pour le GM-CPHD	169
n_{nt}	Nombre moyen de cibles naissantes pour le GM-CPHD	169
$\hat{N}_k^{\mathcal{A}}$	Estimation du nombre de cibles dans un agrégat \mathcal{A}	114
$N_k^{\mathcal{A}}$	Nombre de cibles dans un agrégat \mathcal{A}	114
$n_b^{\mathcal{A}}$	Nombre moyen de cibles naissantes dans la ZOI réduite entourant l'agrégat \mathcal{A}	115
$n_b^{\mathcal{A}}$	Nombre moyen de cibles naissantes sur la zone d'observation	115
$n_{fa}^{\mathcal{A}}$	Nombre moyen de fausses alarmes dans la ZOI réduite entourant l'agrégat \mathcal{A}	115
$\mathbf{N}^{\mathcal{A}}$	Nombre d'agrégats détectés à l'itération précédente	150
Off^s	Indicateur de sortie route possible sur le segment s	101
$P_\Gamma(n)$	Probabilité de naissance de n cibles	41
$p_{k k-1}(n)$	Probabilité <i>a priori</i> d'avoir n cibles à l'itération k	41
$p_{k k}(n)$	Probabilité <i>a posteriori</i> d'avoir n cibles à l'itération k	41

$P_{\kappa}(n)$	Probabilité d'avoir n fausses alarmes	43
P_g	Probabilité de fenêtrage	49
P_s	Probabilité de survie	41
P_d	Probabilité de détection	35
$P_{k,j}$	Covariance estimée de la piste j à l'itération k	18
$P_{k k}$	Covariance estimée associée à $\hat{X}_{k k}$	50
$P_{k,i}^{\mathcal{G}}$	Covariance de la gaussienne i à l'itération k	82
P_{\perp}^s	Matrice de projection sur le segment s	95
$P_{k k}^{\rightarrow s}$	Covariance estimée projetée sur le segment s à l'itération k	97
$P_{k,i}^i$	Probabilité que la cible i à l'itération k soit de type i	17
$P_l^{\Omega}(A)$	Plausibilité d'un élément A	27
$P_{k,i}^{\gamma}$	Covariance de la gaussienne i correspondant à une cible naissante à l'itération k	77
$\mathbf{P}\mathbf{x}$	Matrice symétrique de proximité des cibles	113
$P_k^{\mathcal{A}}$	Covariance de l'agrégat \mathcal{A} à l'itération k	114
$p_{k k}^{\mathcal{A}}(n)$	Probabilité d'avoir n cibles dans l'agrégat \mathcal{A} à l'itération k	114
q_k^p	Poids de la particule p à l'itération k	45
q	Bruit d'état pour un filtre	36
q^{PHD}	Bruit de modèle du filtre PHD	169
Q_k	Matrice de covariance du bruit d'état q	36
$Q_{k,l}^s$	Matrice de covariance du bruit d'état suivant le modèle l et contraint au segment s	96
$q^{\Omega}(A)$	Communalité d'un élément A	27
$R_{k,i}$	Matrice de covariance du bruit d'une observation i à l'itération k	16
R_{θ_s}	Matrice de rotation de l'état dans la direction θ_s engendrée par le segment routier s	96
$S_{k k-1}(\zeta)$	RFS des cibles survivantes issues des états précédents ζ à l'itération $k - 1$	40
$s_{k,j}$	Score estimée de la piste j à l'itération k	18

s_{opt}	Segment optimal dans le cadre de la projection optimisée	99
$\mathcal{T}_{k,j}$	Piste j à l'itération k	18
\mathcal{T}_k	Ensemble des pistes à l'itération k	17
\mathcal{T}_k^{CPHD}	Ensemble des pistes issues du filtre CPHD à l'itération k	73
\mathcal{T}_k^{MHT}	Ensemble des pistes issues du filtre MHT à l'itération k	73
\mathbf{T}_j^k	Séquence d'états de la piste j à l'itération k	18
\mathbf{T}^k	Séquence des pistes jusqu'à l'itération k	18
$\mathcal{T}_{s_i \rightarrow s_{i+1}}$	Transformation entre deux segments successifs	98
$\mathcal{T}_{s_i \rightarrow s_{i+N_s}}$	Combinaison des projections successives permettant de projeter du segment s_i jusqu'au segment s_{i+N_s}	98
\mathfrak{T}_r	Tronçon routier r	100
U	Matrice de transfert	160
U_1	Seuil pour le pruning	169
U_2	Seuil pour le merging	169
\mathcal{U}	Ensemble des matrices de transfert possibles	169
$v_{k k-1}$	Fonction d'intensité <i>a priori</i>	40
$v_{k k}$	Fonction d'intensité <i>a posteriori</i>	40
V	Volume de validation	49
V_k	Volume d'observation à l'itération k	15
v_{min}	Vitesse minimale de détection	168
v_{mti}	Vitesse du capteur	168
v_{max}	Vitesse maximale des cibles	169
$V_k^{\mathcal{A}}$	Aire de la ZOI réduite entourant un agrégat \mathcal{A}	114
$w_{k,i}^{\}$	Poids de la gaussienne i à l'itération k	82
W_k	Matrice de poids à l'itération k	86
$W_{k,a}^{\}$	Poids global de l'association a à l'itération k	87
$\hat{x}_{k k,j}^{(i)}$	État estimé partiel de la cible j associée à la mesure i à l'itération k ..	54

$\hat{X}_{k k}$	État estimé multicible	35
x_k^p	État de la particule p à l'itération k	46
X_k^p	État de la particule multicible p à l'itération k	46
X_k	État réel multicible	37
$x_{k,j}$	État vrai d'une cible j à l'itération k	15
$[x_{k,j}, y_{k,j}]$	Coordonnées position dans le repère (O, X, Y)	15
$[\dot{x}_{k,j}, \dot{y}_{k,j}]$	Coordonnées vitesse dans le repère (O, X, Y)	15
$\hat{x}_{k,j}$	État estimé de la piste j à l'itération k	18
$x_{k,j}^s$	État contraint au segment s d'une cible j à l'itération k	94
$[x_{k,j}^s, y_{k,j}^s]$	Coordonnées position dans le repère (O, X, Y) contraintes au segment s	94
$[\dot{x}_{k,j}^s, \dot{y}_{k,j}^s]$	Coordonnées vitesse dans le repère (O, X, Y) contraintes au segment s	94
$(\hat{x}_{k,i}^n, \hat{y}_{k,i}^n)$	Position estimée de la cible i à l'itération k avec le jeu de mesures n	157
$(\hat{\dot{x}}_{k,i}^n, \hat{\dot{y}}_{k,i}^n)$	Vitesse estimée de la cible i à l'itération k avec le jeu de mesures n	157
$\hat{x}_{k,j}^{\rightarrow s}$	État estimé projeté sur le segment s de la piste j à l'itération k	96
$[\tilde{x}, \tilde{y}]$	Une position dans le repère cartésien local $(O, X, Y)_{TGL}$	16
$\hat{x}_{k k-1,j}$	Position prédite de la cible j	49
$\hat{x}_k^{\mathcal{A}}$	Barycentre de l'agrégat \mathcal{A} à l'itération k	157
$\hat{\dot{x}}_k^{\mathcal{A}}$	Vitesse de l'agrégat \mathcal{A} à l'itération k	157
$w_{k,i}^{\mathcal{G}}$	Poids d'une gaussienne i à l'itération k	82
W_k	Matrice de poids à l'itération k	86
$W_{k,a}^{\mathcal{G}}$	Poids global d'une association a à l'itération k	87
W_0	Poids initial d'une gaussienne	169
$w_{k,i}^{\gamma}$	Poids d'une gaussienne correspondant à une cible naissante i à l'itération k	77
\tilde{Z}_k	RFS des mesures réellement issues de cibles à l'itération k	40
$z_{k,i}$	Plot MTI i à l'itération k	15

$z_{k,i}^{\mathcal{G}}$	Plot MTI i à l'itération k avec attribut d'identité	17
Z_k	Ensemble des mesures MTI à l'itération k	15
\mathbf{Z}^k	Séquence des mesures MTI jusqu'à l'itération k	16
$z_{k,i}^{\mathcal{S}}$	Plot SAR i à l'itération k	17
$z_{k,i}^{\mathcal{V}}$	Plot vidéo i à l'itération k	17
Z^{mti}	Altitude du capteur	168
ζ	Un état précédent	40

Liste des abréviations

ARMSE	Average Root Mean Square Error	156
CPHD	Cardinalized Probability Hypothesis Density	41
CPPF	Coupled Partition Particle Filter	48
COA	Course of Action	11
DEN	Dynamic Evidential Network	145
DRI	Détection, Reconnaissance et Identification	17
DTED	Digital Terrain Elevation Data	19
EAP	Expected <i>a posteriori</i>	38
EFA	Ensemble Fini Aléatoire	40
EKF	Extended Kalman Filter	44
ESM	Electronic Support Measurement	9
FBO	Filtre Bayésien Optimal	50
GBT	Generalized Bayes Theorem	31
GM-CPHD	Gaussian Mixture Cardinalized Probability Hypothesis Density	44
GM-PHD	Gaussian Mixture Cardinalized Probability Hypothesis Density	44
GMTI	Ground Moving Target Indicator	15
HMM	Hidden Markov Model	62
IPPF	Independant Partition Particle Filter	47
JDL	Joint Director of Laboratories	6
JLO	Jensen, Lauritzen et Olesen	141
JPDAF	Joint Probabilistic Data Association Filter	55
MAP	Maximum <i>a posteriori</i>	38
MHT	Multiple Hypothesis Tracker	50
MMC	Modèle de Markov Caché	62
MOE	Mesure d'efficacité	11
MOP	Mesures de performance	11
NN	Nearest Neighbor	49
OSPA	Optimal SubPattern Assignment	163
PCR5	Proportional Conflict Redistribution rule no 5	104
PDAF	Probabilistic Data Association Filter	54
PHD	Probability Hypothesis Density	40
RFS	Random Finite Set	40
RMSE	Root Mean Square Error	157
SAR	Synthetic Aperture Radar	17
SIC	Systèmes d'Information et de Commandement	11
SIG	Système d'Information Géographique	18
UKF	Unscented Kalman Filter	44
ROHUM	Renseignement d'Origine HUMaine	9
RSS-SPRT	Road Set Segment based on Sequential Probability Ratio Test	99
TOMHT	Track Oriented Multiple Hypothesis Tracker	51
TTT	Target Type Tracker	104

VS-IMMC-	Variable Structure-Interacting Multiple Model with constraints - Multiple	
MHT	Hypothesis Tracker	94
ZOI	Zone Of Interest	114

Introduction

Le traitement de l'information constitue un enjeu majeur pour le XXI^{ème} siècle. Le développement des nouvelles technologies, d'internet et des téléphones portables a radicalement bouleversé nos modes de vie, car multipliant la quantité d'information dont nous disposons. Pour faire face à ce flux d'informations, des techniques de fusion de données ont alors été développées. Le domaine militaire, et plus particulièrement celui de la surveillance, a connu les mêmes bouleversements durant les deux dernières décennies. C'est pourquoi, le C3R (pour Commandement, Conduite, Communication et Renseignement) a pour objectif la maîtrise de l'information. Il s'agit d'assurer le recueil, le traitement, la diffusion et le stockage des informations nécessaires à tous les échelons, du niveau politique au niveau tactique sur le terrain. Les systèmes d'informations se sont alors développés au niveau opérationnel, au niveau de la communication ainsi que du renseignement. Par ailleurs, des moyens ont été mis en œuvre pour assurer la fonction de renseignement. Sur le constat qu'une information donnée par un capteur et confirmée par un autre améliore grandement la confiance accordée à cette information, on comprend que l'avenir du renseignement militaire est au multicapteur, justifiant ainsi le développement de techniques de fusion de données. D'une part, les informations reçues sont de nature et d'emprise différente. D'autre part, la quantité d'information et de données à traiter croît de manière très importante. Par ailleurs, il ne faut pas que les informations pertinentes soient noyées sous la quantité d'informations. L'enjeu est donc double. Il faut développer les techniques de fusion de données pour fournir une information à plus haut niveau, c'est ce qu'on appelle l'évaluation de situations. Par ailleurs, il faut que le traitement de l'information soit partiellement automatisé. Au niveau tactique, on souhaite que le traitement de l'information soit fait en quasi temps réel afin d'être le plus réactif possible.

Dans le domaine de la surveillance du champ de bataille, l'évaluation de situation désigne l'opération de détection des entités présentes sur une zone d'observation donnée, ainsi que l'évaluation de leur relation entre elles (amie, ennemie, ...) et avec leur environnement (proche d'un site sensible, à portée de tir, ...). Pour réaliser cette opération d'évaluation de situation, les opérationnels disposent d'une quantité très importante de données issues de sources de nature et d'emprise différentes. Or, l'analyse de ces données peut s'avérer longue (plusieurs heures) car la quantité et l'hétérogénéité des informations dépassent les capacités d'analyse d'un opérateur. Cela constitue une limite forte à l'exploitation et l'utilisation des données pour la planification de capteurs ainsi que pour la prise de décisions tactiques. Afin d'améliorer le travail des opérationnels, il est judicieux de réaliser une analyse préalable automatique de la situation en organisant le traitement de l'ensemble des données. L'analyse préalable consiste à détecter l'ensemble des entités présentes mais également à détecter des objets dits d'« intérêt ». Une attention toute particulière est portée sur l'objet « convoi » qui constitue un objet de haut intérêt opérationnel car il reflète un déplacement stratégique de troupes ou de matériels. De plus, de par ses caractéristiques techniques et opérationnelles, cet objet est particulièrement

difficile à détecter et peut donc servir de modèle de base pour la détection d'objets d'intérêt de nature différente. Un autre aspect important du problème de l'évaluation de situation est que cette dernière doit être réalisée en coopération avec les opérationnels du domaine. Si certains modules de l'évaluation peuvent être complètement automatisés car jugés comme suffisamment fiables, d'autres modules doivent pouvoir être partiellement pilotés par les utilisateurs, qui pourraient sélectionner, par exemple, des taux pour la fiabilité des sources (*cf.* chapitre 2 de [Bloch 2003]).

Parmi l'ensemble des données utilisées par les opérationnels, un des types de données le plus riche en informations sont les données GMTI (Ground Moving Target Indicator). Celles-ci sont issues de capteurs aéroportés capables, par mesure de l'effet Doppler, de détecter les objets terrestres en mouvement sur une large zone d'observation (plusieurs km²). Elles fournissent donc à chaque instant d'acquisition du capteur, un ensemble de mesures décrivant les positions des véhicules mobiles au sol. Bien que ces données soient fortement bruitées, elles ont l'avantage d'être affranchies des conditions climatiques et les capteurs fonctionnent aussi bien de jour que de nuit. Cependant, elles ne sont pas exploitables directement dans le cadre d'une évaluation de situations et nécessitent une étape de traitement préalable appelée pistage ou trajectographie, qui doit être adaptée au contexte d'acquisition. Le but du pistage est d'estimer l'état des cibles mobiles (position et vitesse) à chaque instant d'acquisition du capteur et de fournir un ensemble de pistes, décrivant l'évolution cinématique des cibles. Dans ce cadre, les techniques de trajectographie doivent prendre en compte certaines caractéristiques liées au capteur (biais spatio-temporel, probabilité de fausses alarmes, pouvoir de résolution,...) aussi bien que liées à l'application terrestre (manœuvrabilité des cibles, quantité importante de mesures, quantité importante de véhicules qui démarrent, s'arrêtent, entrent ou sortent de la zone d'observation).

Les autres types de données disponibles dans le cadre de la surveillance d'un théâtre des opérations sont les images SAR (Synthetic Aperture Radar) qui permettent de détecter les cibles immobiles et de fournir une information de classification sur les objets détectés. Les images vidéos optiques, quant à elles, fournissent une information très fiable de classification, voire d'identification, mais sur une zone d'observation très limitée et sur un laps de temps très court. De plus, elles dépendent fortement des conditions climatiques et ne sont disponibles que le jour.

L'opération de combinaison de ces informations est appelée « fusion de données ». Or, la fusion de données pour la détection d'objets d'intérêt est un domaine de recherche assez peu exploité. En effet, si un modèle de fusion de données appelé JDL (Joint Directors Laboratories) [A.N. Steinberg 2004] existe et permet de hiérarchiser les différents niveaux de fusion, la notion de détection d'objets d'intérêt pour l'évaluation de la situation comme étape intermédiaire est un concept nouveau. Par ailleurs, la détection de convoi est un problème complexe sur lequel peu d'auteurs se sont penchés. Quelques travaux existent [Corbeil 2006, Klemm 2008, Koch 2002], mais ceux-ci sont basés sur l'étude de la signature radar des données GMTI dont nous ne disposons pas dans notre étude. Nous proposons donc une démarche nouvelle pour la détection de convoi. Cette dernière est basée sur l'étude des pistes issues des données GMTI. Bien que cette démarche n'ait pas été adoptée par d'autres auteurs par le passé, nous considérons qu'avec l'amélioration des performances

physiques des capteurs GMTI et la création d’algorithmes de pistage multicible de plus en plus performants, la précision de l’estimation de l’état des cibles individuelles d’un convoi est suffisante pour intégrer le comportement de chacune d’elles dans un modèle décrivant le comportement d’un convoi. Dans le cadre de cette thèse, nous proposons donc une méthode en deux étapes qui sont décrites dans le schéma de la figure 1.

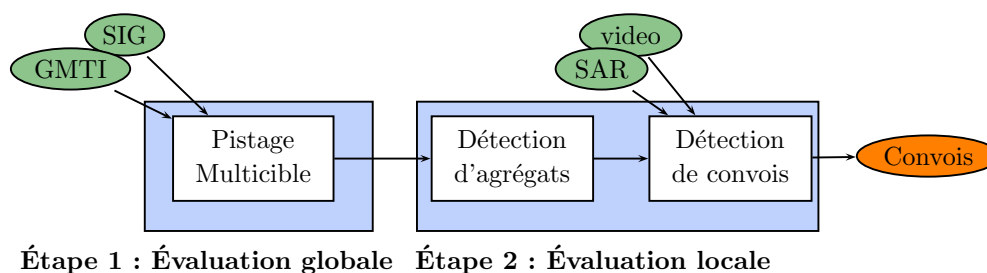


Fig. 1 – Processus de détection de convois - GMTI : *Ground Moving Target Indicator* - SIG : *Système d’Information Géographique* - SAR : *Synthetic Aperture Radar*

Les objectifs de ces travaux de thèse sont les suivants. Tout d’abord, on souhaite réaliser une évaluation globale de la situation. Il s’agit alors de détecter et d’évaluer avec précision l’ensemble des objets présents sur une zone d’observation. Afin de rendre l’analyse de la situation pertinente, on souhaite également détecter des objets d’intérêt, en particulier des convois de véhicules. Une première étape consiste à détecter et qualifier des cibles mobiles susceptibles d’appartenir à un agrégat de véhicules, grâce à l’utilisation d’une technique de pistage à partir des données GMTI. Dans une deuxième étape, on cherchera à reconnaître des convois de véhicules par des méthodes de fusion de données en intégrant éventuellement d’autres types d’informations (SAR, vidéo, ...).

Nous avons constaté qu’aucune technique de pistage n’était parfaitement adaptée à la trajectographie d’un grand nombre de cibles, dont le nombre varie à chaque instant et qui contient des groupes de véhicules. C’est ce qui justifie la première étape de notre travail. Afin de pister aussi bien les cibles distantes les unes des autres que les agrégats de véhicules sur une large zone d’observation, nous avons développé une nouvelle technique de trajectographie multicible. Ensuite, à partir des pistes issues de la méthode de pistage, nous avons développé dans un deuxième temps un modèle de réseau bayésien pour la détection de convois et envisagé les deux théories probabiliste et crédibiliste pour ce qui concerne la fusion bas niveau. Notons, que comme pour n’importe quelle représentation symbolique, l’utilisation des réseaux bayésiens a nécessité une phase de modélisation.

Notre manuscrit de thèse est décomposé en quatre parties. La première partie constitue traditionnellement l’état de l’art. À travers l’énoncé du problème décrit ci-dessus, il apparaît qu’une étude approfondie de la littérature concernant la fusion de données était nécessaire afin d’organiser correctement le traitement des informations disponibles. Une réflexion particulière a été menée sur la notion de **contraintes** et il apparaît que nos travaux se distinguent des travaux antérieurs par la volonté d’intégration d’un grand nombre

de contraintes (cinématique, comportementale, ...) autres que les classiques contraintes spatio-temporelles. Après avoir choisi comme référence le modèle JDL, nous avons analysé la problématique et les données disponibles. Par la suite, nous avons répertorié les grandes approches pour le pistage afin de dégager les avantages et inconvénients de ces dernières. Finalement, nous nous sommes intéressés aux trois approches probabiliste, crédibiliste et possibiliste de traitement de l'information; ainsi qu'aux différentes représentations symboliques envisageables pour la création d'un modèle pour l'objet convoi. La deuxième partie du manuscrit (partie I) concerne l'élaboration d'une technique de pistage multicible aussi bien efficace pour le pistage de cibles proches que pour des cibles distantes. Cette partie a fait l'objet d'une publication dans la revue *IEEE Aerospace and Electronic Systems* [Pollard pear]. Dans cette étape, nous avons tout d'abord comparé les avantages et inconvénients de chacune par rapport à notre problématique. Puis, parmi les techniques retenues, nous avons sélectionné deux approches, le MHT (Multiple Hypothesis Tracker) et le PHD (Probability Hypothesis Density), afin de créer un algorithme hybride qui combine leurs avantages (chapitre 2). Cette étape comporte deux contributions principales. D'une part, une nouvelle technique de labellisation pour le filtre PHD a été envisagée. D'autre part, un processus d'hybridation a été conçu. Enfin, nous avons amélioré les performances de pistage par l'introduction des coordonnées des routes afin de rendre l'algorithme le plus robuste possible (chapitre 3). À partir des résultats obtenus avec cet algorithme, la troisième partie du manuscrit décrit l'utilisation d'une technique de fusion de données pour la détection d'objets d'intérêt (partie II). Dans un premier temps, nous avons étudié les différentes techniques afin de sélectionner la technique la plus adaptée à notre système, c'est à dire un système avec des données hétérogènes, asynchrones voire manquantes, contenant des variables aléatoires pouvant dépendre du temps. Ensuite, nous avons adapté la technique choisie, à savoir les réseaux bayésiens, à notre application de détection de convois (chapitre 4). Et afin de rendre l'étude la plus complète possible, nous avons adapté les réseaux bayésiens à la théorie crédibiliste afin d'étudier l'apport du conflit et du doute dans notre modèle (chapitre 5). L'ensemble des résultats obtenus sont présentés dans la partie III. Tout d'abord, des mesures de performances (MOP) pertinentes sont présentées (chapitre 6), ainsi que l'ensemble des résultats obtenus avec des données simulées (chapitre 7) afin de tester la robustesse des algorithmes aux variations de paramètres. Enfin, afin de prouver la robustesse des algorithmes créés et la justesse des modélisations proposées, nous montrons les résultats obtenus avec des données réelles (chapitre 8).

Évaluation de situations : état de l'art et analyse de la problématique

Sommaire

1.1	Hiérarchisation des niveaux de fusion	7
1.1.1	Contexte	7
1.1.2	Les avantages de la fusion multicapteur	8
1.1.3	Applications	9
1.1.4	Architecture de fusion de données	9
1.1.5	Le Joint Directors of Laboratories	9
1.2	Analyse du problème	11
1.2.1	Définition d'un objet d'intérêt	12
1.2.2	Définition d'un convoi	13
1.2.3	Description des données	14
1.2.4	Bilan	19
1.3	Différentes approches pour traiter l'information	20
1.3.1	La théorie probabiliste	20
1.3.2	La théorie possibiliste	22
1.3.3	La théorie crédibiliste	24
1.3.4	Le conditionnement	30
1.3.5	Comparaison des différentes méthodes	33
1.4	Pistage multicible	35
1.4.1	Synthèse du problème d'estimation	35
1.4.2	Modélisation d'une cible	35
1.4.3	Les enjeux du pistage multicible	36
1.4.4	Le filtre PHD	40
1.4.5	Le filtrage particulaire	44
1.4.6	Les méthodes de type Kalman	49
1.4.7	Comparaison des différentes méthodes	56
1.5	Différentes approches pour représenter un système	58
1.5.1	Les graphes	58
1.5.2	Les automates	58
1.5.3	Les gabarits	60
1.5.4	Les réseaux bayésiens	61
1.5.5	Les modèles de Markov cachés	62
1.5.6	Les réseaux de neurones	63
1.5.7	Les réseaux de Petri	63
1.5.8	Les chroniques	64

Introduction

Dans le cadre de la surveillance du champ de bataille, l'évaluation de situations est une opération complexe. En effet, une situation fait intervenir de nombreux acteurs dont le comportement peut évoluer au cours du temps et dans un environnement donné. De plus, elle est observée par plusieurs capteurs de nature et d'emprise différentes. Or, tout l'enjeu du sujet réside dans la définition de ce qu'est une situation dynamique et de ce qu'il peut y avoir de pertinent, de remarquable, voire d'anormal dans celle-ci. Autrement dit, l'enjeu de l'évaluation de situation est de définir et/ou détecter des objets d'intérêt en fonction de l'objectif opérationnel recherché en exploitant au mieux les données disponibles. Par ailleurs, les différentes sources d'informations fournissent des données incertaines, incomplètes et imprécises ce qui peut nuire à l'analyse de la situation. Il est donc nécessaire de mettre en œuvre un processus dynamique de fusion de données adapté au problème. L'aspect temporel est très important, car pour évaluer de manière pertinente une situation, il ne suffit pas de prendre une *photo* d'une scène à un instant donné. On souhaite plutôt observer et analyser au cours du temps le comportement des entités présentes et leurs relations entre elles ainsi qu'avec leur environnement.

Dans ce cadre et après étude de la littérature, nous avons constaté que le modèle du JDL (Joint Director of Laboratories) est très adapté à notre problématique. Il s'agit d'un modèle de fusion de données basé sur la hiérarchisation des niveaux de fusion et qui permet d'aller des systèmes d'observations jusqu'à l'évaluation de la menace, autrement dit du global vers le local, grâce aux différents niveaux de fusion. Ainsi, le premier niveau a pour but de détecter les entités présentes sur la zone d'observation. Le deuxième consiste à situer ces entités par rapport à leur environnement et par rapport à la dynamique de la scène, tandis que le troisième niveau sert à évaluer en quoi le placement des entités dans leur environnement peut être remarquable, et comment ces entités peuvent être définies comme des objets d'intérêt.

Ce chapitre est donc composé de cinq parties qui présentent la démarche scientifique que nous avons suivie. Dans un premier temps, nous nous sommes intéressés au concept de fusion de données et aux différents modèles qui y sont attachés et plus particulièrement le modèle JDL (Partie 1.1) pour savoir comment organiser notre travail. Dans une deuxième partie, nous avons analysé notre problème et notre application, à savoir la surveillance du champ de bataille. Celle-ci (Partie 1.2) contient donc une description de l'application, ses enjeux tactiques et les données utilisées. Il est nécessaire de décrire précisément les données à ce stade du manuscrit, car elles conditionnent les techniques que nous allons décrire par la suite. Ainsi, la partie 1.3 est un comparatif des différentes théories traiter l'information dans le cadre de la fusion de données et notamment la théorie des probabilités qui est à la base de l'ensemble des techniques de pistage décrites dans la partie 1.4. Finalement, dans la partie 1.5, un descriptif des différentes méthodes utilisables pour la représentation symbolique de l'application est réalisé. Ces trois dernières parties servent à justifier les choix effectués, quant aux algorithmes mis en œuvre.

1.1 Hiérarchisation des niveaux de fusion

1.1.1 Contexte

La fusion de données désigne l'ensemble des techniques permettant de combiner des informations issues de sources de nature et/ou de portée différentes. Une information, par nature, peut être incertaine (on ignore si elle est vraie), imprécise (bruit sur les mesures), et incomplète. Le but de la fusion de données est donc de combiner plusieurs informations afin de réduire l'imprécision et l'incertitude et d'augmenter la complétude, permettant d'obtenir une information globale plus fiable, voire plus pertinente par rapport à une problématique donnée.

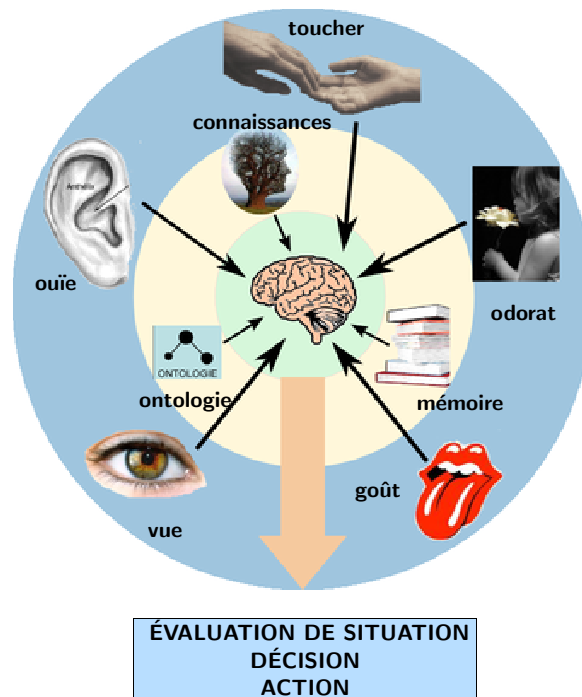


Fig. 1.1 – Un système de fusion de données : le cerveau humain - en bleu : les sens - en jaune : les métadonnées

Le cerveau humain est un exemple particulièrement performant de système de fusion de données illustré par la figure 1.1. En effet, pour des activités élémentaires (marcher, manger, ...) aussi bien que complexes (activité de conduite, préparation d'un repas, ...), l'homme fait appel à ses différents capteurs : ses sens (en bleu sur le schéma), ainsi qu'à certaines métadonnées (en jaune), comme les connaissances *a priori*, les connaissances *a posteriori* issues de sa mémoire, ou encore la logique que l'on peut aussi modéliser sous forme d'ontologies. Ainsi, pour mener à bien des activités élémentaires comme marcher, l'homme fait appel principalement à ses différents sens (vue, toucher) mais également à son orientation pour se rendre au bon endroit. Pour mener à bien une activité plus complexe, il peut faire appel à l'ensemble de ses cinq sens et à un grand nombre de métadonnées. Lors d'une activité de conduite par exemple, l'homme fait appel à sa vue pour naviguer, à son ouïe pour analyser le bruit du moteur ainsi que son environnement, son toucher pour tourner le volant et utiliser les pédales, son odorat, éventuellement pour détecter une panne moteur ; plus un grand nombre de métadonnées : ses connaissances sur le code de

la route, les connaissances antérieures qu'il a du trajet à effectuer ou des ontologies pour s'orienter, etc.

À travers ces exemples, toute la difficulté pour mettre en œuvre un processus de fusion de données apparaît. Pour des activités complexes comme la conduite autonome, remplacer un conducteur nécessite d'utiliser un réseau adapté de capteurs. Ensuite modéliser le comportement d'un individu dans l'environnement de conduite requiert de combiner judicieusement les informations issues des capteurs.

1.1.2 Les avantages de la fusion multicapteur

Les avantages d'utiliser plusieurs capteurs paraissent assez évidents dans la nature. Aussi, l'homme dans des activités de surveillance, va-t'il reproduire ces comportements naturels et mettre en œuvre des systèmes de fusion de données multicapteurs homogènes ou hétérogènes. C'est bien sur également le cas dans des applications militaires et de surveillance du champ de bataille. Dans certains domaines, comme le pistage passif de cibles, l'utilisation de plusieurs capteurs de même nature est judicieuse. En effet, l'utilisation d'un seul capteur radar ne permet pas la localisation exacte des objets, alors que l'utilisation conjointe de plusieurs capteurs radars passifs permet, par un système de triangulation, de localiser avec une plus ou moins grande précision des objets, comme illustré par la figure 1.2.

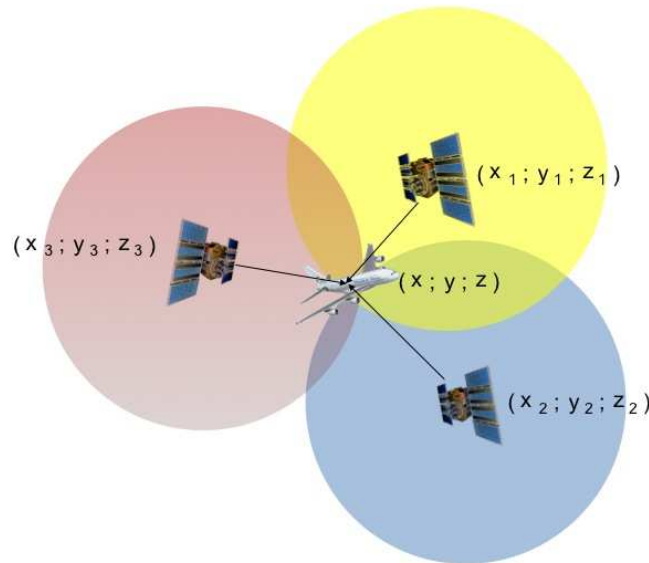


Fig. 1.2 – Illustration de l'utilité de la fusion de données homogènes - la triangulation de plusieurs radars passifs

Quant à la fusion de données hétérogènes, ses avantages apparaissent de manière évidente puisqu'elle permet de combiner des informations de natures diverses, autrement dit des « points de vue » différents, tout en proposant des solutions pour gérer l'incertitude et l'imprécision. Pour revenir sur l'exemple de conduite autonome [Dickmanns 2007], il apparaît que l'utilisation de caméras seules ne permet pas de garantir une conduite sécurisée. Il peut être approprié d'ajouter des radars télémétriques pour calculer à quelle distance sont les objets qui entourent le véhicule, un gps pour le localiser, etc.

1.1.3 Applications

La fusion de données a de nombreuses applications dans le domaine militaire comme dans le domaine civil. Dans le domaine militaire, il peut s'agir d'activités de surveillance comme la surveillance des océans, la surveillance aérienne ou encore la surveillance du champ de bataille [Koller 2006]. Les applications sont également très diverses dans le domaine civil pour plusieurs champs d'applications différents comme la météorologie et la prédiction du temps. Plus localement, des techniques de fusion de données sont utilisées pour la classification de masses nuageuses ou de masses de glace par exemple, pour la prédiction du temps à plus long terme [Wittenbrink 1996, Ameur 2007, Pohl 1998, Soh 1999]. Ces deux dernières applications sont liées à la télédétection qui désigne l'ensemble des techniques utilisées pour déterminer les caractéristiques de la surface et de l'atmosphère de la Terre [Ehlers 1991, Simone 2002].

La fusion de données connaît encore de nombreuses applications civiles comme le traitement d'images médicales [Barillot 1994], la télémédecine [Bellot 2002], les services d'aide à la personne [Lymberopoulos 2008] ou la biologie [Synnergren 2009]. Il existe également de nombreuses applications industrielles telles que le contrôle de robot ou de machines.

1.1.4 Architecture de fusion de données

L'architecture d'un système de fusion de données peut se définir à partir de plusieurs niveaux hiérarchiques. Nous avons retenu trois niveaux de base (*cf.* Figure 1.3). L'architecture dépend bien entendu de l'application et peut être un mélange des trois niveaux de base que nous avons retenus. Ces trois niveaux sont dénommés « fusion directe », « fusion d'attributs » et « fusion haut niveau » [Hall 2001]. Il est entendu que sur la figure, différents types d'images sont utilisées dans un but illustratif, mais que les différentes architectures sont valables quel que soit le type des données utilisées. La fusion directe se place au niveau de traitement le plus bas où les données brutes issues des capteurs sont fusionnées. Le niveau intermédiaire correspond à la fusion d'attributs extraits des données brutes. En effet, les différents capteurs ne fournissent pas toujours des informations sur le même cadre de discernement ; la fusion d'attributs permet donc de ramener des données issues des différents capteurs sur un cadre de discernement commun. Finalement, avec la fusion haut niveau, les données issues de chaque capteur sont traitées pour obtenir une décision quant à la problématique étudiée et c'est l'ensemble des décisions qui sont fusionnées.

Plusieurs modèles ont été proposés pour organiser la mise en œuvre du processus de fusion de données, comme le modèle *Omnibus* [Bedworth 2000] ou le JDL. Ce dernier se veut très généraliste et est adapté aussi bien pour les applications militaires que non militaires [Hall 1997]. Par conséquent, nous allons le décrire plus précisément dans la partie suivante.

1.1.5 Le Joint Directors of Laboratories

Le Joint Directors of Laboratories (JDL) est un modèle de fusion de données hétérogènes. Celles-ci proviennent de différentes sources d'informations : des capteurs physiques fournissant des données numériques (GMTI, SAR, ESM, ...), des informateurs humains (ROHUM) produisant des informations généralement symboliques, ou encore des bases de données comme celles contenues dans les Systèmes d'Informations Géographiques (SIG). Historiquement, le modèle JDL, créé pour la première fois en 1986 par l'armée américaine,

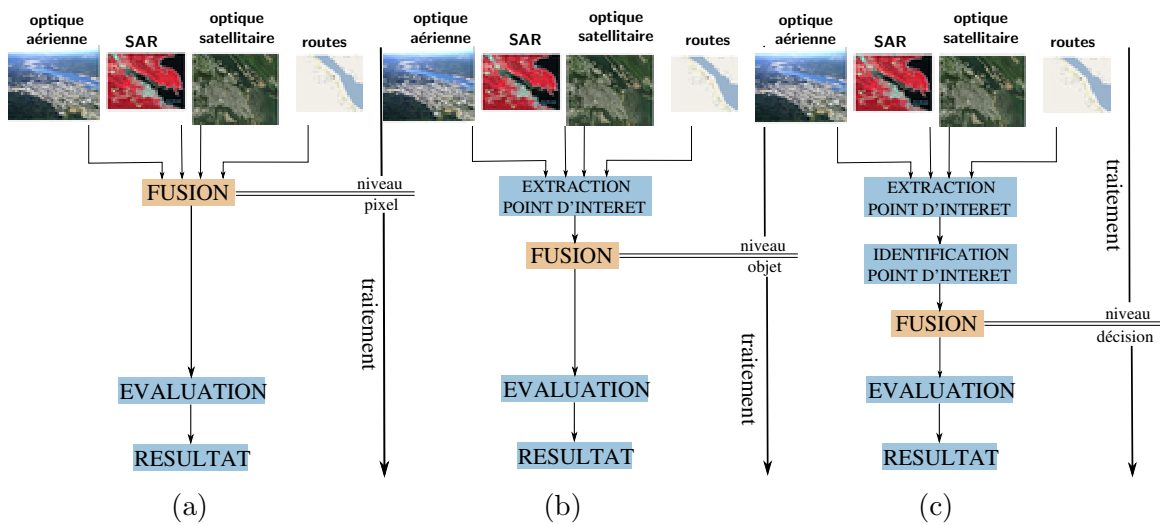


Fig. 1.3 – Différentes architectures de traitement - (a) Fusion directe - (b) Fusion d'attributs - (c) Fusion haut niveau

propose des niveaux de fusion pour atteindre des objectifs opérationnels tels que la localisation de cibles, la tenue de situation, l'évaluation de la menace ou la planification de capteurs. Il a été réactualisé par Steinberg en 1998 [A.N. Steinberg 1998], puis en 2004 [A.N. Steinberg 2004]. Le schéma de principe du JDL dans sa dernière version est présenté dans la figure 1.4.

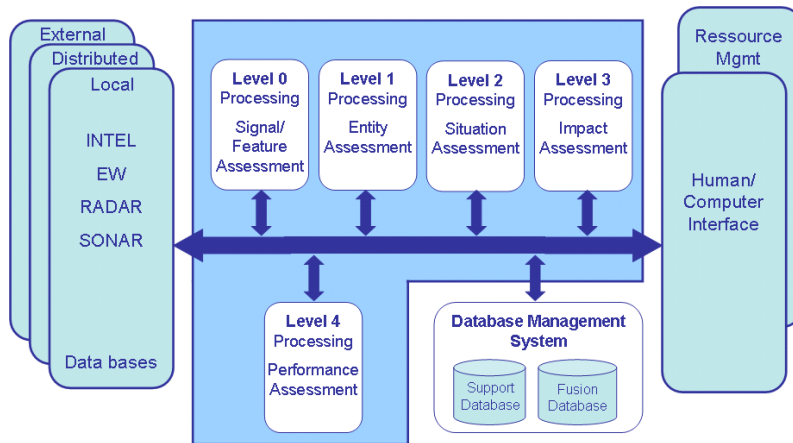


Fig. 1.4 – Schéma de principe du JDL

Les différents blocs entrant en interaction sont les suivants :

Sources : Celles-ci peuvent être issues de capteurs locaux (capteurs qui envoient leur données directement au système de fusion de données), distribuées (réseaux de capteurs) ou externes (connaissances *a priori*, informations géographiques, ...).

Niveau 0 : Prétraitement des données et extraction des informations des sources (extraction des images, des mesures, conversion des données, filtrage des mesures, ...).

Niveau 1 : Prédiction et estimation de l'état des entités (position, vitesse, identité, ...).

Niveau 2 : Évaluation de la situation par la compréhension du rôle propre des entités et/ou des relations existant entre elles ainsi que par rapport à leur environnement.

Niveau 3 : Évaluation de l'impact/menace pouvant entraîner la mise en œuvre de nouveaux procédés (COA : Course of Action) à partir des informations issues des processus de fusion de niveau 0, 1 et 2.

Niveau 4 : En fonction des objectifs de la mission, amélioration du processus d'acquisition des données, en faisant intervenir au besoin de nouveaux systèmes de renseignements (planification de capteurs) dans le but d'améliorer la qualité des informations issues des processus de fusion de niveau 1, 2 et 3 évaluées grâce à des mesures de performance et d'efficacité (MOP, MOE).

Human Computer Interface : L'interface homme/machine est l'outil de visualisation des résultats de fusion obtenu. Par exemple, l'Onera possède ainsi une station de fusion de données appelée *Sofi* qui possède une interface homme/machine attractif.

Database Management System : Ces bases de données servent à enregistrer et stocker tous les résultats obtenus lors d'une mission.

L'avantage de cette classification des niveaux de fusion est qu'elle permet d'utiliser en entrée un nombre significatif de données de types différents.

Concernant le niveau 2, une situation est un état partiel du monde. Certaines structures peuvent être caractérisées par l'état des entités et les relations existant entre elles. Mais définir quelles entités, quels états et quelles relations font partie d'une relation ou sont pertinents pour définir une situation, sont une part importante du problème d'évaluation de la situation (appelée *Situation Assessment* dans la littérature anglaise) et de la sémantique de la situation (*Situation Semantics* en anglais). Toute la difficulté de la sémantique de la situation réside dans la façon de définir la situation de façon abstraite c'est à dire de trouver des caractéristiques physiques qui définissent des objets comme des objets d'intérêt par rapport à leur environnement.

Le niveau 3 est particulièrement difficile à concevoir, car il peut faire intervenir la notion de comportement humain, pas toujours rationnel, de comportement normal ou anormal ou encore connu ou inconnu. Or, si modéliser des comportements connus est déjà une tâche ardue, modéliser un comportement anormal/inconnu est par essence abstrait (comment démontrer l'inexistence?) et fait appel à des raisonnements abductifs¹. Il est donc difficile de créer une méthodologie systématique; la fusion de données à un aussi haut niveau nécessite la plupart du temps une intervention humaine.

1.2 Analyse du problème

Notre application se place dans le cadre de la surveillance du champ de bataille au niveau des Systèmes d'Information et de Commandement (SIC) et plus précisément au niveau tactique. A ce niveau, le but est d'établir une évaluation fiable de la situation terrestre à partir de différents capteurs et agents opérant dans une zone d'intérêt; et ce, quasiment en temps réel. En effet, l'évaluation de la situation au niveau opératif est réalisée actuellement sur un laps de temps plus long (de l'ordre de plusieurs heures). Or, si une menace potentielle est détectée, il faut réagir bien plus rapidement. Nous proposons donc

¹En psychologie cognitive, l'abduction est une forme de raisonnement intuitif qui consiste à supprimer les solutions improbables.

de détecter et d'évaluer des objets d'intérêt les plus pertinents possibles pour l'évaluation de la situation puis de la menace afin de raccourcir la boucle de décision dans la gestion de la planification de capteurs ainsi que pour le ciblage, afin d'accroître les capacités de planification de capteurs ou de diminuer le temps dans un processus de ciblage. Il peut être également envisageable d'intervenir au niveau 4 du JDL (planification de capteurs) en lançant des algorithmes locaux puissants en cas de détections d'objets d'intérêt nécessitant un traitement local particulier.

Cette partie s'articule donc autour de trois axes. Dans une première partie, nous définissons ce qu'est un objet d'intérêt sur le champ de bataille, puis nous nous intéressons dans une deuxième partie à un objet d'intérêt particulier qu'est le convoi. Finalement, les données disponibles pour répondre à notre problématique sont décrites dans la troisième partie.

1.2.1 Définition d'un objet d'intérêt

Le but de notre application est de détecter les objets dit « d'intérêt » afin de faire une évaluation de la situation tactique d'une scène la plus fiable possible. Les enjeux sont donc multiples. Tout d'abord la définition de ce qu'est un objet d'intérêt est fondamentale.

1.2.1.1 Qu'est ce qu'un objet d'intérêt ?

Un objet d'intérêt est un objet physique ou un ensemble d'objets physiques possédant des caractéristiques dignes d'intérêt dans le cadre d'une application donnée. Voici une liste non-exhaustive d'objets définis comme d'intérêt par les opérationnels.

- Convoi
- Véhicule statique sur une crête
- Brusque accélération d'une cible à proximité d'une unité
- Sortie de route
- Véhicule s'arrêtant à proximité d'une zone sensible (exemple : centrale nucléaire)
- Demi-tour

Ainsi, dans le cadre de la surveillance du champ de bataille, les critères d'intérêt pour les objets physiques et leur environnement peuvent être les suivants (liste non exhaustive) :

Critère de positionnement géographique : un objet situé en haut d'une crête devient un objet d'intérêt car sa localisation géographique a un intérêt stratégique.

Critère de type : un char par exemple peut devenir un objet d'intérêt de par ses armes et sa portée.

Critère de comportement collectif : plusieurs véhicules suivant la même trajectoire et ayant la même vitesse constituent un convoi ce qui est opérationnellement intéressant. Un regroupement important d'objets est également intéressant à détecter car cela traduit une grande activité.

Critère de comportement vis à vis de l'environnement : un véhicule sortant de la route est potentiellement intéressant. En effet, il peut agir de la sorte pour une raison stratégique à déterminer.

Critère de comportement vis à vis de la situation tactique : lorsqu'un véhicule s'approche d'un site dit « sensible » (centrale nucléaire, centre de communication, ...).

1.2.1.2 Modélisation par l'étude des contraintes

Dans un premier temps, le modèle décrivant le comportement des objets d'intérêt doit être défini. Cela constitue une part importante du problème de leur détection. Afin de rester généraliste, nous proposons d'analyser les contraintes liées aux objets d'intérêt. En effet, au vu des critères pouvant définir un objet d'intérêt, l'analyse de la situation sur le champ de bataille implique un grand nombre de contraintes sur le comportement observé des objets d'intérêt :

Les contraintes temporelles : durée des événements, corrélation temporelle.

Les contraintes spatiales : pour les objets (position, direction, distance, ...) et pour les zones d'intérêt (route, zone à risque, élévation de terrain, ...).

Les contraintes cinématiques : vitesse et accélération des objets.

Les contraintes tactiques : information *a priori* sur les manœuvres, Ordre de Bataille, informations contextuelles.

Les contraintes numériques : comportement semblable d'un grand nombre de véhicules.

Les contraintes géopolitiques : conflit dans la zone observée, attaques récentes, ...

L'enjeu du choix de la méthode de modélisation est donc de pouvoir prendre en compte le maximum de ces contraintes.

La problématique de détection d'objets d'intérêt est une opération difficile de par la multiplicité des contraintes. Cela est d'autant plus ardu que la plupart des applications se limitent à la gestion des contraintes temporelles et spatiales. De plus, les sources sont multiples et hétérogènes ce qui implique encore des problèmes de compatibilité des données. Enfin, dans ce contexte, les décisions du système doivent être explicables et justifiables auprès d'un opérateur. Finalement, au vu de la complexité du problème, nous souhaitons dans un premier temps être capables de détecter un objet d'intérêt qui soit suffisamment généraliste pour que sa méthode de détection puisse être appliquée à d'autres objets d'intérêt. Nous nous intéressons donc dans un premier temps à l'objet « convoi » qui est d'un grand intérêt opérationnel (ravitaillement, déplacement de troupes, ...) mais qui est très difficile à détecter et à évaluer de par la proximité des cibles qui le composent.

1.2.2 Définition d'un convoi

Les experts du domaine décrivent un convoi comme un ensemble de véhicules se déplaçant ensemble, ayant des objectifs communs et s'apportant mutuellement support. Les véhicules évoluent approximativement selon la même cinématique, le plus souvent sur route et à une vitesse n'excédant pas 80 km.h^{-1} . En conséquence, la vitesse des véhicules est toujours la même au cours du temps (sauf en cas d'arrivée à proximité d'un réseau routier urbain). De même, la distance séparant les véhicules est toujours la même. Une règle de base pour les véhicules du convoi est qu'ils doivent rester à vue les uns des autres, pour pouvoir stopper le convoi en cas d'incident pour l'un des véhicules. Cependant, la distance les séparant doit être suffisamment grande pour qu'en cas d'attaque, ou de passage sur une mine d'un des véhicules, il n'y ait pas de collision en chaîne (sur route, par temps clair, la distance les séparant est donc d'environ 100m). En cas de passage en milieu urbain, les véhicules se rapprochent afin d'éviter que des véhicules civils ne se mêlent au convoi.

D'autres comportements sont possibles comme cela est décrit dans la doctrine américaine sur les déplacements de convois [USM 2001].

1.2.2.1 Définition des contraintes liées à l'objet d'intérêt « convoi »

En considérant l'objet d'intérêt convoi, certaines contraintes sont dégagées à partir de la définition donnée précédemment.

Contraintes temporelles : la durée d'observation doit être relativement longue.

Contraintes spatiales : distance entre les véhicules suffisamment constante.

Contraintes cinématiques : vitesse des véhicules.

Contraintes numériques : nombre de véhicules supérieur à 2.

Contraintes contextuelles : si par exemple un ROHUM fournit l'information du passage d'un char sur une route, l'hypothèse de présence d'un convoi peut être renforcée.

De plus, il peut être intéressant de prendre en compte la finalité opérationnelle d'un objet d'intérêt. Par exemple pourquoi des objets évoluent-ils en convoi ? En règle générale, ils se comportent ainsi pour se déplacer ensemble d'un point A à un point B. Le lieu de destination peut-être une zone stratégique ou une zone de ravitaillement. Donc sur cette hypothèse, il est possible de définir encore un ensemble de règles. Ainsi, nous pouvons supposer que les véhicules vont choisir le trajet le plus court et suivre une route. Selon le type de la route (autoroute, route départementale, chemin, pas de suivi de route), nous disposons d'une indication sur l'évolution de l'objectif du convoi : plus le convoi est proche de son objectif, plus les routes sur lesquelles il évolue sont petites. Les informations de type contextuel (coordonnées des routes, élévation de terrain, ...) sont donc à intégrer dans le processus de fusion de données.

1.2.3 Description des données

Après avoir défini le type des objets d'intérêt que nous souhaitons détecter, il convient maintenant de décrire plus précisément les données à disposition. Nous distinguons d'abord les données issues de capteurs (MTI, SAR, vidéo), des données issues de bases de données (coordonnées des routes, élévation de terrain). Puis, nous modélisons les pistes issues des techniques de trajectographie qui peuvent être vues également comme des données pour le processus de fusion. Mais avant, nous décrivons le modèle d'état et le repère utilisé pour décrire les entités présentes.

1.2.3.1 Positionnement dynamique des cibles

Nous désignons sous le terme de cibles l'ensemble des véhicules motorisés agissant sur le théâtre des opérations. Ces véhicules sont observés par des capteurs chargés notamment de les localiser dans le monde. Dans ce but, nous utilisons deux repères : un repère de positionnement global dans le monde (le WGS 84) et un repère local.

Le système géodésique mondial WGS84 (de l'anglais World Geodetic System créé en 1984) est un système de référencement géographique permettant d'exprimer des positions dans le référentiel Terre. Les positions s'expriment en latitude (la) et longitude (lo) par rapport au repère géocentré ($G, X_{E84}, Y_{E84}, Z_{E84}$) et en altitude par rapport au géoïde terrestre. Le géoïde terrestre est une représentation de la surface terrestre plus précise qu'une simple modélisation sphérique ou ellipsoïdale, puisqu'il est défini de façon à coller

au plus près de la surface réelle. Le système géodésique mondial WGS84 est traditionnellement utilisé pour fournir les coordonnées de positionnement des GPS, ce qui a assuré sa popularité. L'ensemble de ces repères est illustré par la figure 1.5.




Fig. 1.5 – Représentation du repère cartésien local et du repère géocentré - local (O, X, Y, Z) - géocentré ($G, X_{E84}, Y_{E84}, Z_{E84}$)

Lors d'une opération de surveillance d'une zone d'intérêt, un référentiel cartésien local (O, X, Y, Z) est défini. L'origine O du repère est donné par un opérateur, généralement dans le référentiel géographique WGS 84 et les axes (X, Y, Z) sont définis de façon à ce que X soit orienté vers l'Est, Y vers le Nord et Z de façon à compléter le trièdre.

Or, d'après les travaux de Mallick [Mallick 2002], dans le cadre de l'utilisation de données GMTI, l'utilisation des coordonnées altitude Z n'améliore pas la précision de l'estimation de l'état des cibles. Par conséquent, l'état d'une cible j à l'itération k est caractérisé par sa position et sa vitesse dans un repère cartésien local (O, X, Y) tel que :

$$x_{k,j} = [x_{k,j}, \dot{x}_{k,j}, y_{k,j}, \dot{y}_{k,j}]^T \quad (1.1)$$

avec $(x_{k,j}, y_{k,j})$ sa position et $(\dot{x}_{k,j}, \dot{y}_{k,j})$ sa vitesse.

1.2.3.2 Observation des cibles

Dans cette partie, nous décrivons les différents capteurs d'observation des cibles dont nous disposons. Il s'agit des capteurs GMTI, SAR et vidéo.

Les plots MTI Les systèmes d'observation aéroportés GMTI (Ground Moving Target Indicator) permettent de détecter les objets terrestres en mouvement par mesure de leur effet Doppler. Chaque capteur fournit alors, à chaque instant d'acquisition k et sur une large zone d'observation V_k , un ensemble de mesures Z_k de taille m_k variable et tel que :

$$Z_k = \{z_{k,1}, \dots, z_{k,m_k}\} \quad (1.2)$$

Dans le domaine du radar MTI, les mesures appelées également plots MTI sont généralement données sous la forme : distance et angle entre le capteur et l'objet ainsi que sa vitesse radiale. Cependant, conformément au STANAG 4607² [NATO 2007], les mesures

²STANAG est l'abréviation de Standardization Agreement, en français Accords de normalisation pour les systèmes et équipements militaires édités par l'OTAN.

sont fournies en coordonnées WGS84 puis converties dans le repère cartésien. La vitesse radiale n'est pas utilisée dans ces travaux.

Finalement, la mesure i à l'itération k est donnée sous la forme des coordonnées observées (\tilde{x}, \tilde{y}) d'une cible observée $x_{k,j}$ dans le repère local (O, X, Y) telle que :

$$z_{k,i} = [\tilde{x}, \tilde{y}]^T \quad (1.3)$$

Elles sont donc obtenues selon l'équation d'observation suivante :

$$z_{k,i} = H.x_{k,j} + b_k \quad (1.4)$$

où H est la matrice de transformation de l'espace d'état vers l'espace des mesures MTI et b_k est un bruit de mesure lié à la qualité du capteur utilisé.

Il est entendu qu'une mesure i caractérise la cible j , $\forall j \in \{1, \dots, N_k\}$, avec N_k le nombre de cibles à l'itération k , car il n'y a pas de labellisation des mesures.

En considérant les formats mesure et cible (1.1) et (1.3), nous pouvons écrire la matrice de transition H d'un état vers l'autre telle que :

$$H = \begin{pmatrix} 1 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 \end{pmatrix} \quad (1.5)$$

Il est habituellement reconnu que b_k décrit un bruit blanc gaussien centré en 0 de matrice de covariance connue $R_{k,i}$ telle que :

$$R_{k,i} = \mathbb{E} [b_k.b_k^T] \quad (1.6)$$

où la notation $\mathbb{E} [.]$ désigne l'espérance mathématique d'une variable aléatoire.

L'ensemble de toutes les observations depuis l'instant initial jusqu'à l'instant k est noté \mathbf{Z}^k .

Il est à noter que les capteurs GMTI ont une longue période d'échantillonnage ($\Delta = 3$ à 10 s). De plus, les cibles dont la vitesse est supérieure à une vitesse minimum v_{min} , sont détectées avec une probabilité de détection P_d et l'ensemble des mesures contient des fausses alarmes de densité β_{fa} . Cette densité de fausses alarmes est supposée uniforme sur toute la zone d'observation et sa cardinalité peut être modélisée par une loi de Poisson sur le volume d'observation V_k telle que le nombre moyen de fausses alarmes obéit à la relation suivante :

$$N_{fa} = \beta_{fa} \times V_k \quad (1.7)$$

De plus, les données MTI sont également limitées par le pouvoir de résolution du capteur. Lorsque deux cibles sont proches, il est possible qu'au regard de la résolution du capteur une seule cible soit détectée. Ce phénomène est connu sous le nom de **cibles non-résolues** ou **faiblement résolues**.

Par ailleurs, conformément au Stanag 4607, le capteur GMTI est capable de fournir une information sur le type des véhicules détectés, mais assez peu fiable. A chaque mesure

est alors attribuée une identité i_a parmi l'ensemble $\mathcal{I} = \{i^a\}_{\forall a \in \{1, \dots, 9\}}$:

$$\mathcal{I} = \left\{ \begin{array}{c} \text{Pas d'information} \\ \text{Véhicule à chenilles} \\ \text{Véhicule à roues} \\ \text{Avions à voilure fixe} \\ \text{Avions à voilure tournante} \\ \text{Rotor stationnaire} \\ \text{Bateau} \\ \text{Balise} \\ \text{Amphibie} \end{array} \right\} \quad (1.8)$$

Finalement, le format complet d'un plot MTI devient :

$$z_{k,i}^{\mathcal{G}} = \{z_{k,i}, i_{k,i}, P_{k,i}^i\} \quad (1.9)$$

où $i_{k,i}$ représente le type de la cible i parmi l'ensemble \mathcal{I} et $P_{k,i}^i$ est la probabilité estimée d'exactitude de la classification de la cible. Finalement, l'ensemble $\{P_{k,i}^{i^a}\}_{\forall a \in \{1, \dots, 9\}}$, représente les termes diagonaux de la matrice de confusion C^i pour la classification telle que :

$$C^i = [c_{ij} = P\{i_k = i^j | Id = i^i\}] \quad (1.10)$$

Les images SAR Le SAR (Synthetic Aperture Radar) permet de fournir des images radar de très haute résolution. De plus l'interférométrie permet de générer des modèles numériques du terrain. Enfin, de par la très grande résolution des images SAR actuelles, il est possible de reconnaître le type des véhicules au sol (char, voiture, ...) et de localiser les cibles ou les objets immobiles ayant une forte réflectivité (*permanent scatterer*) à l'aide d'algorithmes de Détection, Reconnaissance et Identification (DRI).

Les algorithmes DRI utilisant du SAR nous fournissent donc des informations de classification sous forme de plots à intervalles non réguliers. Nous définissons un plot SAR $z_{k,i}^{\mathcal{S}}$ reçu à l'itération k tel que :

$$z_{k,i}^{\mathcal{S}} = \{z_{k,i}, c_{k,i}\} \quad (1.11)$$

avec $z_{k,i}$ indiquant la position du plot dans le repère local (O, X, Y) comme en (1.3) et $c^{\mathcal{S}}$ est un booléen indiquant si l'objet détecté est de type militaire ou non.

Les images vidéo Conformément au schéma du JDL, il est possible de mettre en œuvre de nouveaux procédés et/ou capteurs en cas d'évolution de la situation. Il est donc envisageable d'utiliser des capteurs portés par des drones pour fournir des images vidéos d'une scène, ce qui permettrait d'identifier par exemple plus précisément les cibles. Des plots VMTI (Video Moving Target Indicator) pourront alors être obtenus dans le formalisme OTAN (STANAG 4609) qui est en cours de finalisation.

Pour l'instant et pour des raisons pratiques, nous utilisons le formalisme suivant : les plots vidéos obtenus, notés $z_{k,i}^{\mathcal{V}}$, sont écrits sous la même forme que les plots SAR tels que, à l'itération k :

$$z_{k,i}^{\mathcal{V}} = \{z_{k,i}, c_{k,i}\} \quad (1.12)$$

1.2.3.3 Localisation des cibles

Les pistes La trajectographie de cibles terrestres, appelée aussi pistage, permet d'assurer le suivi temporel des données cinématiques des cibles (position, vitesse, parfois accélération) sur une zone d'observation. Pour se faire, de nombreuses techniques ont été développées depuis les années 60 (*cf.* Partie 1.4).

Une piste est une suite d'états estimés décrivant la dynamique d'une cible. Le but du pistage est donc de fournir un ensemble de pistes \mathcal{T}_k correspondant à l'ensemble des cibles à chaque itération k . Ce type d'informations peut être utilisé dans le cadre de la détection d'objets d'intérêt tel que :

$$\mathcal{T}_k = \{\mathcal{T}_{k,j}\}_{j \in \{1, \dots, \hat{N}_{k|k}\}} \quad (1.13)$$

Mathématiquement, une piste $\mathcal{T}_{k,j}$ à l'instant k est définie par son état estimé $\hat{x}_{k,j}$, sa covariance $P_{k,j}$ et son score $s_{k,j}$:

$$\mathcal{T}_{k,j} = \{\hat{x}_{k,j}, P_{k,j}, s_{k,j}\} \quad (1.14)$$

Finalement, la notation \mathbf{T}_j^k désigne la séquence d'une piste comme décrit dans l'équation (1.14) qui caractérise l'évolution cinématique d'une cible au cours du temps telle que la séquence des états décrivant une piste s'écrit :

$$\mathbf{T}_j^k = \{\mathcal{T}_{t,j}\}_{t=1}^k \quad (1.15)$$

Le cumul des pistes de l'itération initiale jusqu'à l'itération k est noté \mathbf{T}_k .

Le pistage de l'ensemble des cibles terrestres à partir des données MTI pose de nombreux problèmes : nombre important de données à traiter, problème d'association des mesures aux cibles, grande manœuvrabilité des cibles, ... comme cela est illustré par la figure 1.6.

Par ailleurs, l'utilisation d'informations géographiques contextuelles comme les coordonnées des routes peut améliorer les performances de pistage.

Les Systèmes d'Information Géographiques (SIG) Dans le cadre de la localisation de cibles terrestres, les Systèmes d'Information Géographiques (SIG) permettent d'améliorer la précision de l'estimation des cibles. Il s'agit d'un système d'information qui relie des données à leur emplacement géographique ou cartographique. Ces données pourront ainsi nous fournir des indications sur le type et l'emplacement des routes, ainsi que sur les infrastructures présentes sur le théâtre des opérations. Nous pouvons donc utiliser les coordonnées des routes pour améliorer la précision du pistage. Les routes sont stockées sous la forme d'un graphe permettant de relier différents tronçons, un tronçon étant composé de plusieurs segments routiers et étant délimité soit par une fin de route soit par une intersection. De plus, nous pouvons utiliser une image DTED (Digital Terrain Elevation Data) pour connaître les élévations de terrain. Une image représentant un DTED est montré sur la Figure 1.7 à titre indicatif.

1.2.4 Bilan

Au vu de la complexité du problème de détection d'objet d'intérêt, nous avons décidé de nous focaliser dans un premier temps sur l'objet d'intérêt convoi. En effet, celui-ci regroupe l'ensemble des contraintes définies en 1.2.1.2 et présente un intérêt stratégique




Fig. 1.6 – Cumul des plots MTI *plots MTI en rouge - routes en noir*



Fig. 1.7 – Exemple de DTED - *Les pixels noirs représentent les points de basse altitude et les pixels blancs les points de haute altitude.*

certain. L'objectif est donc de définir une méthode pour la détection de convoi, dans le but de la généraliser à d'autres types d'objets d'intérêt. L'enjeu principal est d'exploiter au mieux les données disponibles (GMTI, SAR, vidéo, ...). Préalablement, nous revenons donc sur les différentes manières de représenter l'information (Partie 1.3) et notamment la théorie des probabilités, qui est un outil de base pour le développement algorithmique. Ensuite, l'idée est d'utiliser une technique de trajectographie pour évaluer globalement la situation à partir des données GMTI. Néanmoins, les techniques usuelles souffrent de déficiences, particulièrement pour le pistage de cibles proches (comme dans un convoi), c'est pourquoi nous décrivons les techniques principales de pistage multicible dans la partie 1.4. Puis, à partir des pistes issues du processus de pistage et des autres types de données, nous souhaitons faire une évaluation plus fine de la situation, notamment par l'étude des relations entre les entités détectées et leur environnement. Cette étape est limitée, dans cette thèse, à la détection de convoi. Or, l'intégration des autres types de données est

un problème très complexe car il s'agit d'intégrer des informations ayant des cadres de discernement distincts. C'est pourquoi, dans la partie 1.5, nous décrivons les alternatives possibles pour la modélisation d'un objet d'intérêt.

1.3 Différentes approches pour traiter l'information

L'analyse de la situation nécessite de fusionner un grand nombre d'informations provenant de différentes sources. Or, la modélisation et la combinaison d'informations sont des étapes clés dans le cadre de la fusion de données. En effet, aucune donnée n'est parfaite et la manière de représenter cette imperfection conditionne les résultats obtenus lors d'une opération de fusion de données. Quatre catégories d'imperfection peuvent être considérées. Une information est :

- **incertaine** : elle peut être erronée.
- **imprécise** : elle peut être approximative (plus ou moins vraie). Par exemple, si on interroge quelqu'un sur l'âge de Paul et qu'il répond : « Paul a 30 ans », alors il est possible que Paul ait effectivement 30 ans, mais il est également possible que Paul ait 31 ans et que la personne ait arrondi à 30 ans.
- **incomplète** : elle peut délivrer seulement une vérité partielle. Par exemple, dans le cadre de la détection d'objets, un capteur peut ne détecter qu'une partie des objets présents.
- **conflictuelle** : si elle est délivrée par plusieurs sources et que les sources ne sont pas d'accord. On parle également d'inconsistance.

C'est dans la manière de traiter ces imperfections que différentes théories pour le traitement de l'information sont nées. Dans cette partie, nous décrivons trois formalismes qui sont couramment utilisées : la théorie des probabilités (*cf.* Partie 1.3.1), la théorie des possibilités (*cf.* Partie 1.3.2) et la théorie des fonctions de croyance (*cf.* Partie 1.3.3). Ces trois formalismes sont généralement décrits dans la littérature portant sur le traitement de l'information [Grandin 2006, Desodt-Lebrun 1996, Bloch 1996].

1.3.1 La théorie probabiliste

Dans un cadre probabiliste, les connaissances sont modélisées sous la forme de distribution de probabilités dans un référentiel. Elles permettent de représenter de manière rigoureuse l'incertitude. Par ailleurs, elles sont le fondement pour de nombreux outils statistiques, comme l'apprentissage. Historiquement, la théorie des probabilités bénéficie d'un cadre mathématique puissant et cohérent. De plus, depuis sa création en 1763 par Bayes et sa popularisation par Laplace, les axiomes énoncés ont été mathématiquement justifiés par Cox en 1946 [Cox 1946].

Dans le cas d'un espace Ω_A fini, un évènement A est une partie quelconque de Ω_A .

Soient A et B deux évènements. Désignons par $P\{A\}$ et $P\{B\}$ les probabilités pour les évènements A et B de se produire. Ces probabilités représentent « l'information *a priori* » dont nous disposons sur les évènements A et B .

Si A et B sont indépendants, la probabilité d'avoir à la fois l'évènement A et l'évènement B est égale au produit des probabilités de chaque évènement :

$$P\{A, B\} = P\{A\} \times P\{B\} \quad (1.16)$$

S'il existe une relation de causalité entre un symptôme A défini sur Ω_A et une maladie B définie sur Ω_B . La probabilité qu'un patient soit dans l'état « malade » est alors égale à la somme de la probabilité que le patient soit malade en ayant le symptôme avec la probabilité que le patient soit malade sans avoir le symptôme. C'est la propriété de **marginalisation** :

$$P\{A\} = \sum_{\forall B \in \Omega_B} P\{A, B\} \quad (1.17)$$

Si l'évènement B se produit, alors il modifie la connaissance que nous avons sur A . Nous disposons alors d'une nouvelle « information *a posteriori* ». C'est la **loi multiplicative** :

$$P\{A|B\} = \frac{P\{A, B\}}{P\{B\}} \quad (1.18)$$

En reprenant avec l'équation 1.17, le théorème des probabilités totales est obtenu :

$$P\{A\} = \sum_{\forall B \in \Omega_B} P\{A|B\} \times P\{B\} \quad (1.19)$$

Naturellement, si A et B sont indépendants, la probabilité conditionnelle de A sur B devient :

$$P\{A|B\} = P\{A\} \quad (1.20)$$

Dans le cas où il existe une relation de causalité entre A et B , plusieurs types d'inférence sont possibles :

Inférence descendante ou prédiction : Connaissant la maladie, quelle est la probabilité $P\{B|A\}$ que le patient développe tel ou tel symptôme ?

Inférence ascendante ou diagnostic : Connaissant le symptôme, quelle est la probabilité $P\{A|B\}$ que le patient soit malade ?

Ces types d'inférence sont calculés grâce au théorème de Bayes :

$$P\{B|A\} = \frac{P\{A|B\} \times P\{B\}}{P\{A\}} \quad (1.21)$$

Ce qui est classiquement traduit par la relation :

$$a \text{ posteriori} = \frac{a \text{ priori} \times \text{vraisemblance}}{c} \quad (1.22)$$

où c est une constante de normalisation.

Cependant, un patient peut développer un symptôme qui n'est pas dû à une maladie mais à d'autres sources (poussière, pollution, ...).

Considérons à présent un ensemble d'évènements $B = \{B_1, \dots, B_N\}$ qui sont autant de causes possibles pour A (cf. Figure 1.8).

L'ensembles des $\{B_i\}_{1 \leq i \leq n}$ sont indépendants conditionnellement à A ce qui est noté $B_i \perp B_j | A$, et vérifie la propriété suivante :

$$\forall (i, j) \in \{1, \dots, n\}, \forall i \neq j, \quad P\{B_i|B_j, A\} = P\{B_i|A\} \quad (1.23)$$

Si l'évènement A se produit, la probabilité que ce soit effectivement l'évènement B_i qui ait causé l'évènement A s'exprime grâce au théorème de Bayes :

$$P\{B_i|A\} = \frac{P\{A|B_i\} \times P\{B_i\}}{\sum_{i=1}^N P\{A|B_i\} \times P\{B_i\}} \quad (1.24)$$




Fig. 1.8 – Multi-causalité entre A et B

Dans le cas où le système étudié Y ne contient pas des évènements mais des variables aléatoires $\{Y_1, \dots, Y_N\}$ continues ou à valeurs discrètes dans $F_1 \times \dots \times F_N$, on note $\mathbf{P}\{Y_i = y_i\} = \mathbf{P}\{y_i\}$ la probabilité que la variable Y_i ait la valeur y_i . Dans le cas où Y_i est à valeurs discrètes, on parle d'une **distribution de probabilités**. Dans le cas où Y_i est continu, il s'agit alors d'une **densité de probabilités** noté $f(y_i)$.

Le théorème des probabilités totales énoncé pour les évènements en (1.19) s'écrit pour des variables aléatoires :

$$f_Y(y) = \int f_Y(y|x)f_X(x)dx \quad (1.25)$$

La densité de probabilités de X à valeurs dans F_X conditionnellement à Y à valeurs dans F_Y s'écrit :

$$f(x|y) = f_X(X = x|Y = y) \quad (1.26)$$

En combinant avec (1.18) et (1.25), la densité de probabilités conditionnelles s'écrit :

$$f(x|y) = \frac{f(y|x) \times f(x)}{\int f(y|x)f(x)dx} \quad (1.27)$$

Finalement, sous l'hypothèse que les variables aléatoires $Y_i, \forall i \leq N$, composant le système Y , le théorème de Bayes généralisé donne :

$$f(y) = f(y_1, \dots, y_N) = f(y_1) \times f(y_2|y_1) \times f(y_3|y_1, y_2), \times \dots \times f(y_n|y_1, \dots, y_{n-1}) \quad (1.28)$$

1.3.2 La théorie possibiliste

La logique floue s'appuie sur la théorie mathématique des ensembles flous [Dubois 1988] introduite par Zadeh en 1965 [Zadeh 1965]. L'idée est de pouvoir manipuler des informations issues du langage naturel, donc subjectif. Ainsi, cette théorie est une extension de la théorie des ensembles classiques pour la prise en compte d'ensembles définis de façon imprécise. À l'inverse de la logique booléenne, la logique floue permet à une condition d'être dans un autre état que « vrai » ou « faux ». De même qu'il n'est pas toujours facile de qualifier la taille d'une personne comme grande ou moyenne, il y a des degrés dans la vérification d'une condition comme l'illustre la figure 1.9.

Ainsi, la connaissance que nous avons d'un système est modélisée par un ensemble de sous-ensembles flous, généralement créé par expertise. Dans l'exemple présenté dans la figure 1.9, le système « Taille d'un individu » est caractérisé par les sous-ensembles $\{\mu_{\text{petit}}, \mu_{\text{moyen}}, \mu_{\text{grand}}\}$. Chaque sous-ensemble flou est ainsi défini par une fonction d'appartenance μ_i qui associe à chaque élément $x \in X$, le degré $\mu_i(x)$, compris entre 0 et 1, avec lequel x appartient à la classe i , tel que

$$\begin{aligned} \mu_i : X &\rightarrow [0, 1] \\ x &\rightarrow \mu_i(x) \end{aligned} \quad (1.29)$$

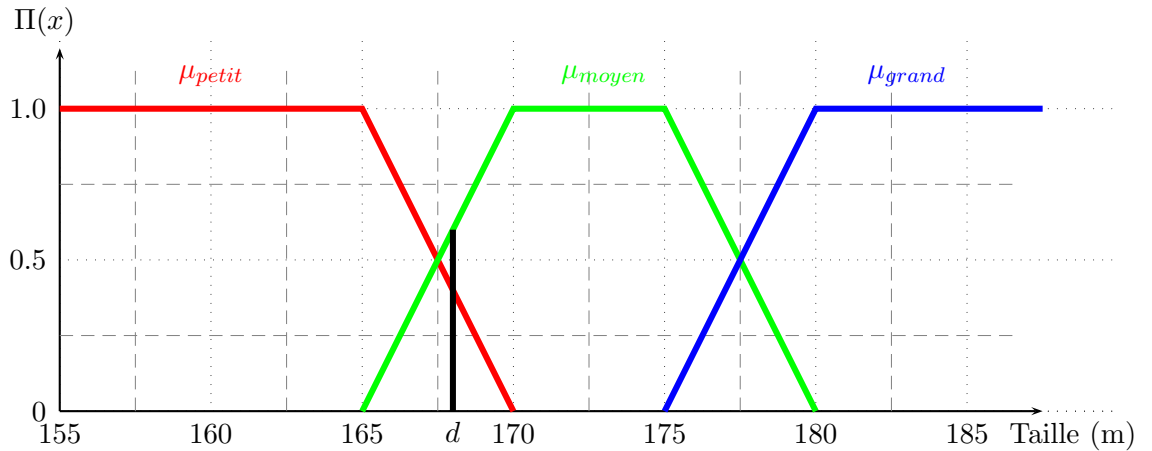


Fig. 1.9 – Sous-ensembles flous représentés par des triangles et des trapèzes - d représente une valeur de taille pour laquelle les possibilités qu'un individu soit de taille petite ou grande est non nulle.

À partir de cette modélisation, il est possible de calculer les possibilités qu'une mesure d appartienne aux différentes classes, tels que $\Pi_d(i) = \mu_i(d)$. Dans l'exemple utilisé, on obtient :

$$\Pi_d(\text{petit}) = 0.4, \quad \Pi_d(\text{moyen}) = 0.6, \quad \Pi_d(\text{grand}) = 0$$

Concernant la fusion de distributions de possibilités, de nombreux opérateurs de combinaisons peuvent être utilisés. Le premier type d'opérateurs est utilisé lorsque les sources sont concordantes : c'est un opérateur conjonctif (ET logique). Par exemple l'opérateur T-norme est défini tel que, $\forall x \in X$:

$$\Pi_{1,2}(x) = \max(\Pi_1(x), \Pi_2(x)) \quad (1.30)$$

Le deuxième type est utilisé lorsque les sources sont discordantes, il s'agit d'un opérateur disjonctif (OU logique). Par exemple, l'opérateur T-conorme est défini comme :

$$\Pi_{1,2}(x) = \min(\Pi_1(x), \Pi_2(x)) \quad (1.31)$$

Il existe de nombreux autres types d'opérateurs tels que les opérateurs « adaptatifs ». Il s'agit d'une classe d'opérateurs qui prend en compte les caractéristiques du contexte (fiabilité des sources, conflit, ...). Ainsi, la règle de Dubois et Prade [Dubois 1991] prend en compte une mesure h_{12} du degré de compatibilité de deux sources tel que :

$$h_{12} = \max_x (\min(\Pi_1(x), \Pi_2(x))) \quad (1.32)$$

Ensuite, la combinaison adaptative des deux distributions de possibilités est obtenu par :

$$\Pi_{1,2}(x) = \max_x \left(\frac{\min(\Pi_1(x), \Pi_2(x))}{h_{12}}, \min(\max(\Pi_1(x), \Pi_2(x))), 1 - h_{12} \right) \quad (1.33)$$




Fig. 1.10 – Opérateur adaptatif - (a) Sources discordantes - (b) Sources concordantes

Plus le conflit h_{12} entre deux informations est grand, plus l'incertitude sur le résultat augmente.

Finalement, la prise de décision peut être faite en sélectionnant le maximum de possibilité.

Le grand avantage de la logique floue est de pouvoir traiter explicitement l'incertitude et l'imprécision ce qui n'était pas le cas auparavant dans le cadre de la théorie probabiliste.

1.3.3 La théorie crédibiliste

La théorie crédibiliste, issue de la théorie de Dempster-Shafer, a été initiée par les travaux de Dempster sur les bornes inférieures et supérieures des probabilités [Dempster 2008] puis formalisée par Shafer dans [Shafer 1976]. Il s'agit d'une généralisation de la théorie des probabilités, puisque l'idée de base est de ne pas considérer les hypothèses seules mais également les unions d'hypothèses, considérant ainsi un cadre de discernement plus large et plus précis pour la modélisation. La contrepartie est une complexité algorithmique plus grande.

Dans nos travaux, nous adoptons le formalisme du modèle des croyances transférables (TBM : Transferable Belief Model) proposé par Smets [Smets 2000]. Dans ce cadre, le processus de gestion d'informations incertaines se déroule en deux étapes : une étape dite « crédale » où les informations sont modélisées sous forme de masse de croyance et une étape dite « pignistique » où les masses de croyance sont utilisées pour la prise de décision. La principale différence entre la théorie de Dempster-Shafer et la TBM réside dans le fait qu'avec la TBM, les distributions de masses de croyance ne sont pas normalisées et la masse de croyances sur l'ensemble vide (conflit) peut être non nulle. Ce cas précis ouvre la question de l'origine du conflit (sources non-fiables, hypothèses manquantes, monde ouvert, ...).

1.3.3.1 Définition des masses de croyances

L'intérêt des fonctions de croyance est la modélisation des connaissances incertaines. Ainsi, si nous considérons un système susceptible d'être dans différents états $\Omega = \{\omega_1, \omega_2, \omega_3\}$, le formalisme des fonctions de croyance consiste à considérer un cadre de discernement plus grand que les hypothèses d'états seules. Ainsi, le cadre de discernement est composé des hypothèses seules et de l'ensemble des unions d'hypothèses représentant le cas où le système peut être dans différents états tels que :

$$2^\Omega = \{\emptyset, \{\omega_1\}, \{\omega_2\}, \{\omega_3\}, \{\omega_1, \omega_2\}, \{\omega_1, \omega_3\}, \{\omega_2, \omega_3\}, \{\omega_1, \omega_2, \omega_3\}\} \quad (1.34)$$

Par la suite, afin d'alléger les notations, nous écrirons l'ensemble $\{\omega_i, \omega_j\}$ de la façon suivante : ω_{ij} .

Pour représenter la connaissance du système, la notion de fonction de masse de croyance notée m^Ω est la plus communément utilisée car sensiblement équivalente à la notion de probabilité telle que :

$$\begin{aligned} m^\Omega : 2^\Omega &\rightarrow [0, 1] \\ A &\rightarrow m^\Omega(A) \end{aligned} \quad (1.35)$$

Ainsi, la masse de croyance attribuée à la proposition $A = \omega_{12}$ modélise le doute exprimé par la source entre les hypothèses ω_1 et ω_2 .

Finalement, la distribution de masses associée à l'ensemble 2^Ω vérifie :

$$\sum_{A \in 2^\Omega} m(A) = 1 \quad (1.36)$$

où chaque sous ensemble $A \in \Omega$ est appelé élément focal de la distribution de masse.

Une fonction de masse est dite normale si $m(\emptyset) = 0$. La masse $m(\emptyset)$ représente la masse de croyance qui ne peut être attribuée à aucune des hypothèses du cadre Ω . Si $m(\emptyset) \neq 0$, il faut se poser la question de savoir l'origine de cette masse. Le cadre de discernement peut être incomplet, autrement dit toutes les hypothèses d'état possibles du système ne sont pas répertoriées. On dit alors que le monde est « ouvert » dans l'espace Ω . Une autre possibilité est qu'un capteur fournisse des informations erronées.

Par ailleurs, en cas d'absence d'information, à l'initialisation par exemple, la totalité de la masse de croyance est attribuée à l'union de toutes les hypothèses $m(\omega_1 \cup \omega_2 \cup \omega_3) = 1$. Avec la théorie des probabilités, on suppose que toutes les hypothèses sont équiprobables et on écrit $P\{\omega_1\} = 1/3$, $P\{\omega_2\} = 1/3$ et $P\{\omega_3\} = 1/3$.

1.3.3.2 Représentation graphiques des masses de croyance

Il est parfois difficile de se faire une « représentation mentale » des fonctions de croyance, particulièrement lorsqu'on possède une solide culture probabiliste. Nous proposons donc ici une nouvelle représentation graphique de ces fonctions de croyance. Ainsi, dans le cadre d'une approche probabiliste, les probabilités sont calculées sur chacun des ensembles de Ω comme illustré par la figure 1.11. Dans le cadre d'une approche crédibiliste, les masses de croyance sont calculées sur tous les sous ensembles de Ω . Traditionnellement, les masses de croyance sont représentées comme dans la figure 1.12, où les croix sont les différentes hypothèses et les cercles/ellipses les différents éléments focaux. Dans cet exemple, tous les éléments de 2^Ω sont des éléments focaux et la représentation graphique est très chargée. Nous proposons donc une nouvelle représentation qui nous paraît plus claire et plus intuitive (*cf.* Figure 1.14) si on comprend l'analogie qui est faite avec la théorie des ensembles dont la représentation graphique est présentée en Figure 1.13. Avec la nouvelle représentation, il est entendu que les hypothèses sont exclusives ($m^\Omega(\omega_1 \cap \omega_2) = 0$). Par ailleurs, la masse des unions d'hypothèses, par exemple $\omega_1 \cup \omega_2$, est placée à l'intersection de ces deux ensembles. Cela permet d'obtenir une représentation graphique cohérente des masses de croyance. Cette représentation, comme nous le verrons par la suite, permet de retrouver intuitivement, les relations d'équivalence entre les différentes fonctions élémentaires, ainsi que les formules de Moëbius [Smets 2002].




Fig. 1.11 – Représentation graphique des probabilités sur Ω




Fig. 1.12 – Représentation graphique classique des masses de croyances sur 2^Ω

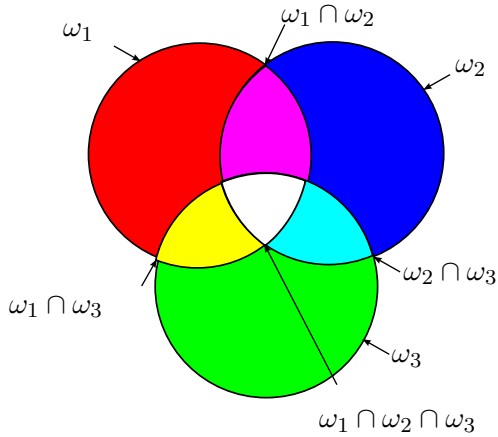


Fig. 1.13 – Représentation graphique des ensembles Ω




Fig. 1.14 – Nouvelle représentation graphique des masses de croyance sur 2^Ω

1.3.3.3 Les différentes fonctions élémentaires utilisant les masses de croyance

À partir d'une fonction de masse $m^\Omega(A)$, il est possible de définir d'autres représentations de l'information appelées **fonctions élémentaires** en relation biunivoque. Cela signifie qu'il existe d'autres représentations qui sont équivalentes et qui peuvent être déduites les unes des autres. Dans le paragraphe suivant, nous décrivons les fonctions élémentaires couramment utilisées ainsi que leur relation biunivoque avec la masse de croyance $m^\Omega(A)$. Pour une compréhension intuitive de ces fonctions élémentaires, nous invitons le lecteur à se référer à l'exemple décrit dans le tableau 1.1.

Crédibilité : la crédibilité d'un élément A est la part minimale de croyance spécifiquement allouée à A qui ne contient pas de masse de croyance conflictuelle et sans le conflit :

$$\forall A \subseteq \Omega, \quad bel^\Omega(A) = \sum_{B \subseteq A, B \neq \emptyset} m^\Omega(B) \quad (1.37)$$

$$\forall A \subseteq \Omega, \quad m^\Omega(A) = \sum_{B \subseteq A} (-1)^{|A|-|B|} bel^\Omega(B) \quad (1.38)$$

$B \subseteq \Omega$	m^Ω	pl^Ω	$bel^{\Omega \setminus \emptyset}$	b^Ω	q^Ω
\emptyset	0.1	0	0	0.1	1
ω_1	0.07	0.46	0.08	0.17	0.46
ω_2	0.12	0.44	0.13	0.22	0.44
ω_{12}	0.22	0.59	0.45	0.51	0.31
ω_3	0.31	0.49	0.34	0.41	0.49
ω_{13}	0.08	0.78	0.51	0.56	0.17
ω_{23}	0.01	0.83	0.48	0.54	0.1
ω_{123}	0.09	0.9	1	1	0.09

Tab. 1.1 – Un exemple de transformation d’une distribution de masses - Le calcul de bel se fait sur l’espace 2^Ω privé de \emptyset .

Plausibilité : la plausibilité d’un élément A est la part maximale de croyance que l’on peut attribuer à A en incluant le doute :

$$\forall A \subseteq \Omega, \quad Pl^\Omega(A) = \sum_{A \cap B \neq \emptyset} m^\Omega(B) \quad (1.39)$$

$$\forall A \subseteq \Omega, \quad m^\Omega(A) = \sum_{B \subseteq A} (-1)^{|A|-|B|+1} pl^\Omega(\bar{B}) \quad (1.40)$$

Implicabilité : L’implicabilité d’un élément A est la part minimale de croyance spécifiquement allouée à A qui ne contient pas de masse de croyance conflictuelle et avec le conflit :

$$\forall A \subseteq \Omega, \quad b^\Omega(A) = \sum_{B \subseteq A} m^\Omega(B) = bel^\Omega(A) + m^\Omega(\emptyset) \quad (1.41)$$

$$\forall A \subseteq \Omega, \quad m^\Omega(A) = \sum_{B \subseteq A} (-1)^{|A|-|B|} b^\Omega(B) \quad (1.42)$$

Communalité : La communalité d’un élément A est la somme des masses de croyance des éléments qui contiennent au moins A :

$$\forall A \subseteq \Omega, \quad q^\Omega(A) = \sum_{B \supseteq A} m^\Omega(B) \quad (1.43)$$

$$\forall A \subseteq \Omega, \quad m^\Omega(A) = \sum_{B \subseteq A} (-1)^{|A|-|B|} q^\Omega(B) \quad (1.44)$$

Exemple : Nous reprenons à présent l’exemple extrait de la thèse d’Emmanuel Ramasso [Ramasso 2007b]. Pour chaque fonction élémentaire, nous décrivons le détail du calcul pour un ensemble singleton ainsi que pour un ensemble union d’hypothèses, et nous proposons une représentation graphique.

Plausibilité :

$$\begin{aligned} pl^\Omega(\omega_1) &= m^\Omega(\omega_1) + m^\Omega(\omega_{12}) + m^\Omega(\omega_{13}) + m^\Omega(\omega_{123}) \\ &= 0.07 + 0.22 + 0.08 + 0.09 \\ &= 0.46 \end{aligned}$$

Et à l'inverse :

$$\begin{aligned}
 m^\Omega(\omega_1) &= (-1)^{|\omega_1| - |\emptyset| + 1} pl^\Omega(\bar{\emptyset}) + (-1)^{|\omega_1| - |\omega_1| + 1} pl^\Omega(\bar{\omega}_1) \\
 &= pl^\Omega(\omega_{123}) - pl^\Omega(\omega_{23}) \\
 &= 0.9 - 0.83 \\
 &= 0.07
 \end{aligned}$$




Fig. 1.15 – Illustration du calcul de $m^\Omega(\omega_1)$ à partir des plausibilités - Le positionnement ω_1, ω_2 et ω_3 est similaire à celui de la figure 1.14

$$\begin{aligned}
 pl^\Omega(\omega_{12}) &= m^\Omega(\omega_1) + m^\Omega(\omega_2) + m^\Omega(\omega_{12}) + m^\Omega(\omega_{13}) \\
 &\quad + m^\Omega(\omega_{23}) + m^\Omega(\omega_{123}) \\
 &= 0.07 + 0.12 + 0.22 + 0.08 + 0.01 + 0.09 \\
 &= 0.59
 \end{aligned}$$

Et à l'inverse :

$$\begin{aligned}
 m^\Omega(\omega_{12}) &= (-1)^{|\omega_{12}| - |\emptyset| + 1} pl^\Omega(\bar{\emptyset}) + (-1)^{|\omega_{12}| - |\omega_1| + 1} pl^\Omega(\bar{\omega}_1) \\
 &\quad + (-1)^{|\omega_{12}| - |\omega_2| + 1} pl^\Omega(\bar{\omega}_2) + (-1)^{|\omega_{12}| - |\omega_{12}| + 1} pl^\Omega(\bar{\omega}_{12}) \\
 &= pl^\Omega(\omega_{23}) + pl^\Omega(\omega_{13}) - pl^\Omega(\omega_3) - pl^\Omega(\omega_{123}) \\
 &= 0.83 + 0.78 - 0.49 - 0.9 \\
 &= 0.22
 \end{aligned}$$




Fig. 1.16 – Illustration du calcul de $m^\Omega(\omega_{12})$ à partir des plausibilités - Le positionnement ω_1, ω_2 et ω_3 est similaire à celui de la figure 1.14

Crédibilité :

$$\begin{aligned}
 bel^{\Omega \setminus \emptyset}(\omega_1) &= m^\Omega(\omega_1) / \sum_{B \neq \emptyset} m^\Omega(B) \\
 &= 0.07 / 0.9 \\
 &= 0.08
 \end{aligned}$$

Et à l'inverse :

$$\begin{aligned}
 m^\Omega(\omega_1) &= (-1)^{|\omega_1| - |\emptyset|} bel^\Omega(\emptyset) + (-1)^{|\omega_1| - |\omega_1|} bel^\Omega(\omega_1) \\
 &= bel^\Omega(\omega_1) - bel^\Omega(\emptyset) \\
 &= 0.07 - 0 \\
 &= 0.07
 \end{aligned}$$

$$\begin{aligned}
 bel^\Omega(\omega_{12}) &= m^\Omega(\omega_1) + m^\Omega(\omega_2) + m^\Omega(\omega_{12}) \\
 &= 0.07 + 0.12 + 0.22 + 0.08 + 0.01 + 0.09 \\
 &= 0.59
 \end{aligned}$$

Et à l'inverse :

$$\begin{aligned}
 m^\Omega(\omega_{12}) &= (-1)^{|\omega_{12}|-|\omega_1|} bel^\Omega(\omega_1) + (-1)^{|\omega_{12}|-|\omega_2|} bel^\Omega(\omega_2) \\
 &\quad + (-1)^{|\omega_{12}|-|\omega_{12}|} bel^\Omega(\omega_{12}) \\
 &= bel^\Omega(\omega_{12}) - bel^\Omega(\omega_1) - bel^\Omega(\omega_2) \\
 &= 0.41 - 0.07 - 0.12 \\
 &= 0.22
 \end{aligned}$$




Fig. 1.17 – Illustration du calcul de $m^\Omega(\omega_{12})$ à partir des crédibilités - Le positionnement ω_1, ω_2 et ω_3 est similaire à celui de la figure 1.14

Le calcul des différentes fonctions élémentaires peut paraître compliqué. Cependant, des relations matricielles existent entre les différentes représentations ; elles sont décrites dans [Smets 2002]

Finalement, la figure 1.18 représente les différentes fonctions élémentaires les unes par rapport aux autres.




Fig. 1.18 – Illustration des différentes fonctions élémentaires

1.3.4 Le conditionnement

Comme dans le cadre des probabilités, il est possible de conditionner une distribution de masses de croyance m^Ω par un évènement $A \subseteq \Omega$. L'exemple présenté sur la figure 1.19 illustre l'évènement « A : le système n'est pas dans l'état ω_3 ».

Dans ce cas, le cadre des propositions est restreint aux états ω_1 ou ω_2 et les masses qui étaient affectées à ω_3 sont donc transférées sur les ensembles inclus dans A comme cela est symbolisé par les flèches dans la figure 1.19.




Fig. 1.19 – Représentation graphique du conditionnement - Le positionnement ω_1 , ω_2 et ω_3 est similaire à celui de la figure 1.14

Mathématiquement, il vient :

$$\forall B \subseteq A, \quad m^\Omega[A](B) = \sum_{C \subseteq \bar{A}} m^\Omega(B \cup C) \quad (1.45)$$

En appliquant la formule (1.45) sur l'exemple, on trouve

$$\left\{ \begin{array}{l} m^\Omega[\omega_{12}](\omega_3) = 0 \\ m^\Omega[\omega_{12}](\omega_1) = \sum_{C \subseteq \omega_3} m^\Omega(\omega_1 \cup C) = m^\Omega(\omega_1 \cup \phi) + m^\Omega(\omega_1 \cup \omega_3) = m^\Omega(\omega_{13}) + m^\Omega(\omega_1) \\ m^\Omega[\omega_{12}](\omega_2) = \sum_{C \subseteq \omega_3} m^\Omega(\omega_2 \cup C) = m^\Omega(\omega_2 \cup \phi) + m^\Omega(\omega_2 \cup \omega_3) = m^\Omega(\omega_{23}) + m^\Omega(\omega_2) \\ m^\Omega\omega_{12} = \sum_{C \subseteq \omega_3} m^\Omega(\omega_{12} \cup C) = m^\Omega(\omega_{12} \cup \phi) + m^\Omega(\omega_{12} \cup \omega_3) = m^\Omega(\omega_{123}) + m^\Omega(\omega_{12}) \end{array} \right.$$

1.3.4.1 Les règles de combinaison

Lorsque deux sources fournissent une distribution de masse, il faut pouvoir les combiner d'une façon adaptée. Il existe de nombreuses règles de combinaisons. Nous décrivons ici simplement les règles conjonctive et disjonctive.

La règle de combinaison conjonctive (CRC : Conjonctive Rule of Combination) permet de combiner des sources indépendantes et fiables.

$$m_1^\Omega \otimes_2(A) = (m_1^\Omega \odot m_2^\Omega)(A) = \sum_{B \cap C = A} m_1^\Omega(B) \cdot m_2^\Omega(C) \quad (1.46)$$

A noter qu'avec la commonalité, la relation est immédiate :

$$q_1^\Omega \otimes_2(A) = (q_1^\Omega \odot q_2^\Omega)(A) = q_1^\Omega(A) \cdot q_2^\Omega(A) \quad (1.47)$$

A titre illustratif comme avec l'exemple 1, si on dispose de deux sources 1 et 2 fournissant une distribution de masses, on trouve :

$$\begin{aligned} m_1^\Omega \otimes_2(\omega_1) &= m_1^\Omega(\omega_1) \cdot m_2^\Omega(\omega_1) + m_1^\Omega(\omega_1) \cdot m_2^\Omega(\omega_{12}) + m_1^\Omega(\omega_{12}) \cdot m_2^\Omega(\omega_{123}) \\ &\quad + m_1^\Omega(\omega_{123}) \cdot m_2^\Omega(\omega_{12}) + m_1^\Omega(\omega_1) \cdot m_2^\Omega(\omega_{123}) + m_1^\Omega(\omega_{123}) \cdot m_2^\Omega(\omega_1) \end{aligned}$$

et

$$\begin{aligned}
 m_1^\Omega \oplus_2(\omega_{12}) &= m_1^\Omega(\omega_{12}).m_2^\Omega(\omega_{12}) + m_1^\Omega(\omega_{12}).m_2^\Omega(\omega_1) \\
 &\quad + m_1^\Omega(\omega_1).m_2^\Omega(\omega_{12}) + m_1^\Omega(\omega_{12}).m_2^\Omega(\omega_1) \\
 &\quad + m_1^\Omega(\omega_2).m_2^\Omega(\omega_{12}) + m_1^\Omega(\omega_{12}).m_2^\Omega(\omega_2) \\
 &\quad + m_1^\Omega(\omega_{12}).m_2^\Omega(\omega_{12})
 \end{aligned}$$

La règle de combinaison disjonctive (DRC : Disjunctive Rule of Combination) permet de combiner des sources indépendantes et dont l'une au moins est fiable :

$$m_1^\Omega \oplus_2(A) = (m_1^\Omega \oplus m_2^\Omega)(A) = \sum_{B \cup C = A} m_1^\Omega(B).m_2^\Omega(C) \tag{1.48}$$

A noter qu'avec l'implicabilité, la relation est immédiate :

$$b_1^\Omega \oplus_2(A) = (b_1^\Omega \oplus b_2^\Omega)(A) = b_1^\Omega(A).b_2^\Omega(A) \tag{1.49}$$

Cette règle a l'avantage d'être associative et commutative. Cependant, elle n'est pas idempotente. Cela signifie que si l'on combine deux fois les mêmes distributions de masse, alors on ne retrouve pas cette même distribution. En effet, la masse de croyance est transférée vers les sur-ensembles des éléments focaux dans un processus de généralisation [Smets 2002].

A titre illustratif, comme avec l'exemple 1, si on dispose de deux sources 1 et 2 fournissant une distribution de masses, on trouve :

$$m_1^\Omega \oplus_2(\omega_1) = m_1^\Omega(\omega_1).m_2^\Omega(\omega_1)$$

On voit immédiatement que si on combine la masse $m_1^\Omega(\omega_1)$ avec elle même, on trouve $m_1^\Omega \oplus_1(\omega_1) < m_1^\Omega(\omega_1)$ Par ailleurs, la combinaison de masses de croyances sur l'union d'hypothèses donne :

$$\begin{aligned}
 m_1^\Omega \oplus_2(\omega_{12}) &= m_1^\Omega(\omega_1).m_2^\Omega(\omega_2) + m_1^\Omega(\omega_2).m_2^\Omega(\omega_1) \\
 &\quad + m_1^\Omega(\omega_1).m_2^\Omega(\omega_{12}) + m_1^\Omega(\omega_{12}).m_2^\Omega(\omega_1) \\
 &\quad + m_1^\Omega(\omega_2).m_2^\Omega(\omega_{12}) + m_1^\Omega(\omega_{12}).m_2^\Omega(\omega_2) \\
 &\quad + m_1^\Omega(\omega_{12}).m_2^\Omega(\omega_{12})
 \end{aligned}$$

1.3.4.2 Le théorème de Bayes généralisé




Fig. 1.20 – Causalité entre deux variables

Considérons le cas simple présenté en figure 1.20 avec les cadres de discernement Ω et Θ . Si on connaît les distributions de masses sur Ω pour chaque élément $\theta_k \in \Theta$ conditionnellement aux éléments $\omega_k \in \Omega$, on peut calculer la distribution de masse sur Θ grâce au théorème de Bayes généralisé (Generalized Bayes Theorem : GBT). Comme la masse de

croissance est en relation biunivoque avec la plausibilité ou la commonalité, il est possible d'exprimer le théorème de Bayes généralisé grâce à n'importe lesquelles de ces grandeurs :

$$pl^\Theta[\omega](\theta) = 1 - \prod_{\theta_i \in \theta} (1 - pl^\Omega[\theta_i](\omega)) \quad (1.50)$$

$$q^\Theta[\omega](\theta) = \prod_{\theta_i \in \theta} pl^\Omega[\theta_i](\omega) \quad (1.51)$$

$$m^\Theta[\omega](\theta) = \prod_{\theta_i \in \theta} pl^\Omega[\theta_i](\omega) \cdot \prod_{\theta_i \in \bar{\theta}} (1 - pl^\Omega[\theta_i](\omega)) \quad (1.52)$$

Une réflexion très documentée et très poussée sur le problème de combinaison d'informations a été menée par Smets dans [Smets 2007a].

1.3.4.3 Affaiblissement d'une source

Lorsqu'une source est jugée peu fiable, on peut limiter son influence en l'affaiblissant. La nouvelle distribution de masses de croyance ${}^\alpha m^\Omega$ est calculée à partir de la distribution de masses originelle m^Ω et du coefficient d'affaiblissement $\alpha \in [0, 1]$ telle que :

$$\begin{aligned} \forall A \subset \Omega \quad {}^\alpha m^\Omega(A) &= (1 - \alpha) m^\Omega(A) \\ {}^\alpha m^\Omega(\Omega) &= (1 - \alpha) m^\Omega(\Omega) + \alpha \end{aligned} \quad (1.53)$$

1.3.4.4 Utilisation de la probabilité pignistique lors de la prise de décision

Lors de la phase de prise de décision, il faut décider parmi les hypothèses singletons laquelle est la plus probable. La transformation pignistique consiste ainsi à repartir de manière équiprobable la masse d'une proposition d'hypothèses conjointes sur les différentes hypothèses. Autrement dit :

$$\text{BetP}_m(\omega_k) = \frac{1}{1 - m(\emptyset)} \sum_{A \in \Omega} \frac{m(A)}{|A|} \quad (1.54)$$

1.3.4.5 Bilan

Les principaux avantages de la théorie des fonctions de croyance sont la finesse de la modélisation des connaissances. Ainsi, de la croyance est spécifiquement allouée au doute et au conflit. Bien que relativement récente, de nombreux outils et opérateurs de combinaisons ont été développés pour la fusion et la prise de décision. Cependant, les fonctions de croyance se limitent pour l'instant aux espaces discrets, même si des premiers travaux pour généraliser les fonctions de croyances aux espaces continus commencent à être publiés [Doré 2009].

1.3.5 Comparaison des différentes méthodes

Nous avons présenté les principes de la théorie des probabilités, des possibilités et des crédibilités. Les différences résident dans la modélisation de l'imperfection des données et par conséquent dans les manières possibles pour les combiner.

Le tableau 1.2 résume et compare différents aspects liés aux trois théories décrites. Le but, ici, n'est pas de conclure quant à la supériorité d'une théorie sur une autre, mais

de montrer la complémentarité de ces différentes représentations de l'incertain. Chaque théorie peut être plus ou moins adaptée selon le problème traité.

Dans le cadre de nos travaux, nous nous sommes majoritairement appuyés sur le cadre probabiliste, car la majorité des algorithmes de suivi de cibles ont été développés avec ce formalisme. Cependant, nous avons aussi pris appui sur les TBM pour la détection de convoi. En effet, lors de la dernière phase d'évaluation des objets d'intérêt, la précision apportée par les TBM en terme d'analyse (conflit et doute) est particulièrement utile aux opérationnels à qui ces infos sont destinées.

	Probabilité	Possibilité	Croyance
Origine	Bayes (1774)	Zadeh (1965)	Dempster (1974)
Incertitude	oui	oui	oui
Imprécision	non	oui	oui
Abs. connaissance	non : $P\{\omega_1\} = 0.5, P\{\omega_2\} = 0.5$	oui : $\mu_1 = 1, \mu_2 = 1$	oui : $m^\Omega(\omega_1 \cup \omega_2) = 1$
Doute	non	oui	oui
Conflit sources	non	oui	oui
Fiabilité sources	non	oui	oui
Opérateur de fusion	Bayes	T-norme, T-conorme, ...	CRC, DRC, ...
Prise de décision	MAP, MAE ...	Maximum de possibilité/nécessité	Transformation pignistique
Variables discrètes	oui	oui	oui
Variables continues	oui	oui	non
Avantages	Justification axiomatique Cadre math. puissant Outils statistique Apprentissage	Représentation langage naturel Pls. opérateurs de combinaison	Niveaux modélisation/décision Représentation de l'ignorance Mesure du conflit Diff. opérateurs de combinaison
Inconvénients	Confusion méconnaissance/doute Incertitude pas imprécision	Choix des opérateurs de fusion Problème de bord Limites théoriques	Combinatoire

Tab. 1.2 – Avantages et inconvénients des représentations de l'incertain - $\Omega = \{\omega_1, \omega_2\}$

1.4 Pistage multicible

1.4.1 Synthèse du problème d'estimation

Le schéma bloc présenté en figure 1.21 résume schématiquement le problème d'estimation d'un système en règle générale. Il s'agit, à chaque itération k à partir de la séquence des mesures \mathbf{Z}^k , de fournir une estimation de l'état réel du système $\hat{X}_{k|k}$ ainsi que l'incertitude qui y est associée $P_{k|k}$, le système étant caractérisé par un état réel X_k de taille variable N_k .

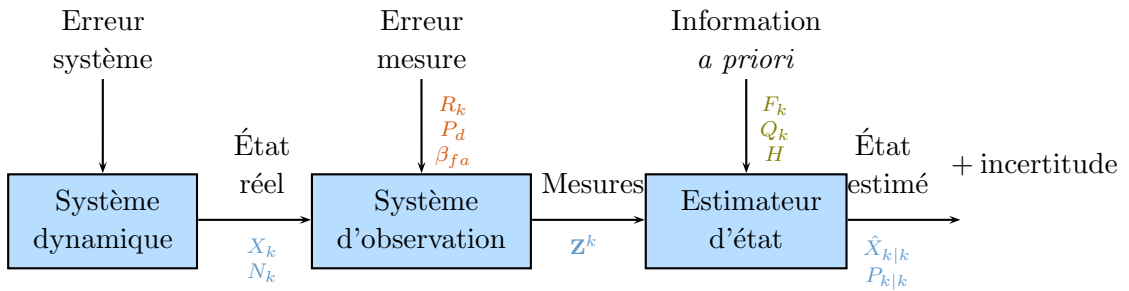


Fig. 1.21 – Schéma bloc du problème d'estimation

Les variables R_k , P_d et β_{fa} en orange caractérisent les erreurs liées aux capteurs et sont supposées connues. Les variables F_k , Q_k et H en vert, décrites par la suite, caractérisent le modèle de description du système. Elles sont également connues mais dépendent du modèle choisi. Aucune variable ne décrit les erreurs systèmes. En effet, des erreurs systèmes sont modélisées pour les systèmes commandés (fusée) uniquement.

1.4.2 Modélisation d'une cible

Dans le cadre du pistage multicible, chaque cible individuelle peut être vue comme un système dynamique indépendant, dont l'évolution temporelle peut être modélisée sous la forme d'une équation. Au vu de la modélisation de l'état d'une cible (*cf.* équation (1.1) et du format des mesures (*cf.* équation (1.3)), nous nous limitons au cas linéaire puisque l'état $x_{k,j}$ d'une cible j à l'itération k est caractérisée par les équations de mouvement (1.55) et d'observation (1.56) par une mesure $z_{k,i}$ suivantes :

$$x_{k+1,j} = F_k \cdot x_{k,j} + \Gamma_k \cdot \nu_{k,j} \quad (1.55)$$

$$z_{k,i} = H \cdot x_{k,j} + b_k \quad (1.56)$$

où F_k est la matrice de transition d'état caractérisant l'évolution du système et H est la matrice de transition de l'espace d'état vers l'espace des mesures décrite en (1.5). $\Gamma_k \cdot \nu_k$ est un vecteur de bruit d'état dont les propriétés statistiques (moyenne, covariance) caractérisent les limites du modèle utilisé (exactitude de la matrice de transition, finesse du modèle d'état). Par exemple, le système modélise un mouvement à vitesse constante. Si le véhicule accélère alors un bruit de mesure apparaît car le modèle n'est pas adapté à ce comportement. Nous décrivons maintenant ces différentes grandeurs avec plus de détails.

Si une cible j est définie par sa position et sa vitesse telle :

$$x_{k,j} = \begin{bmatrix} x_{k,j} \\ \dot{x}_{k,j} \\ y_{k,j} \\ \dot{y}_{k,j} \end{bmatrix} \quad (1.57)$$

alors, si nous considérons que la cible évolue selon une trajectoire rectiligne et avec une vitesse constante, la matrice de transition d'état F_k est telle que :

$$F_k = \begin{pmatrix} 1 & \Delta & 0 & 0 \\ 0 & 1 & 0 & 0 \\ 0 & 0 & 1 & \Delta \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (1.58)$$

car elle correspond au système d'évolution séquentiel suivant :

$$\begin{cases} x_{k+1,j} = x_{k,j} + \Delta \cdot \dot{x}_{k,j} \\ \dot{x}_{k+1,j} = \dot{x}_{k,j} \\ y_{k+1,j} = y_{k,j} + \Delta \cdot \dot{y}_{k,j} \\ \dot{y}_{k+1,j} = \dot{y}_{k,j} \end{cases} \quad (1.59)$$

où Δ est la période d'échantillonnage du capteur GMTI. La matrice F_k traduit donc bien une relation linéaire entre $x_{k+1,j}$ et $x_{k,j}$.

Le bruit $\nu_{k,j}$ est modélisé par un bruit blanc gaussien centré en 0, de covariance connue Q_k qui modélise les incertitudes sur le modèle utilisé tel que :

$$\mathbb{E} \left[[\Gamma_k \cdot \nu_{k,j}] \cdot [\Gamma_k \cdot \nu_{k,j}]^T \right] = \Gamma_k \cdot Q_k \cdot \Gamma_k^T \quad (1.60)$$

et Γ_k permet de décrire l'incertitude comme étant l'erreur de modélisation engendrée par l'approximation effectuée sur l'accélération comme définie par Bar-Shalom dans [Bar-Shalom 2000] :

$$\Gamma_k = \begin{pmatrix} \Delta^2/2 & 0 \\ \Delta & 0 \\ 0 & \Delta^2/2 \\ 0 & \Delta \end{pmatrix} \quad (1.61)$$

Finalement, Q_k s'écrit :

$$Q_k = \mathbb{E} \left[\nu_{k,j} \cdot \nu_{k,j}^T \right] = \begin{pmatrix} \sigma_x^2 & 0 \\ 0 & \sigma_y^2 \end{pmatrix} = q \cdot \begin{pmatrix} 1 & 0 \\ 0 & 1 \end{pmatrix} \quad (1.62)$$

avec σ_x et σ_y les écarts-types respectifs associés à l'incertitude sur les composantes accélération dans les deux directions X et Y du référentiel local. Ils sont considérés égaux et représentés finalement par q le bruit de modèle, autrement dit une mesure de la confiance accordée au modèle.

1.4.3 Les enjeux du pistage multicible

1.4.3.1 Positionnement du problème

Dans le cadre du pistage multicible, on souhaite à l'itération k estimer l'état de l'ensemble des cibles X_k de taille N_k tel que :

$$X_k = \{x_{k,j}\}_{j=1}^{N_k} \quad (1.63)$$

Par ailleurs, la taille de cet ensemble varie au cours du temps, cela signifie que des cibles apparaissent et disparaissent dans la zone d'observation. Le problème d'estimation est donc double : d'une part il faut estimer l'état des cibles de la manière la plus précise possible et d'autre part, il faut estimer le nombre de cibles tout en générant des processus de « vie » et de « mort » pour ces dernières. De manière générale, il s'agit d'un problème d'estimation d'un système linéaire stochastique à dimension variable.

L'ensemble des mesures \mathbf{Z}^k est également de taille variable $m_k \neq N_k$, car l'ensemble des mesures contient des fausses alarmes et des non-détections. Un des aspects du problème est donc l'association des mesures aux cibles. De plus, le volume d'observation V_k varie à chaque itération. Par exemple, dans la figure (cf. Figure 1.22), nous présentons un exemple problématique d'associations de trois mesures à deux cibles

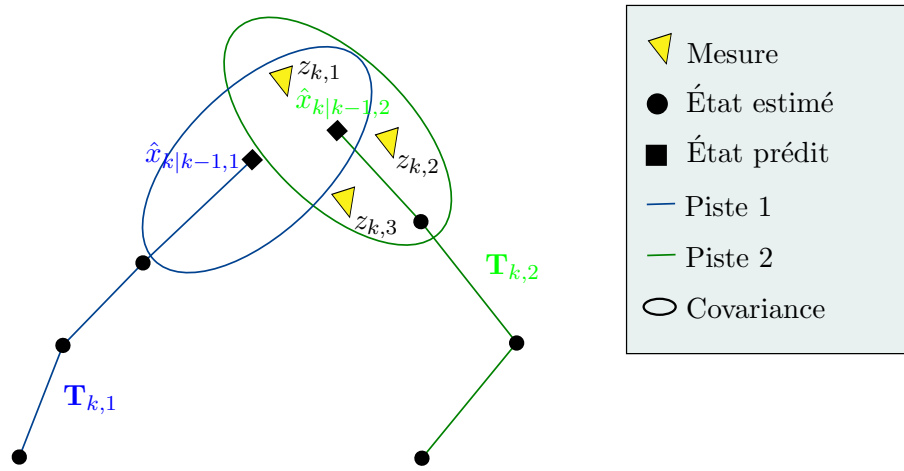


Fig. 1.22 – Scénario problématique d'association

Dans l'exemple, deux cibles interférentes à l'itération k sont considérées, cela signifie que leurs ellipses de covariance se touchent. Il est alors d'usage de parler de regroupement de cibles ou « clustering ». Chacune d'elles est représentée par une piste. A l'itération courante k , le système prédit deux états notés $\hat{x}_{k|k-1,1}$ et $\hat{x}_{k|k-1,2}$.

L'ensemble X_k est donc défini sur un espace continu géométrique. Il peut être vu comme un processus ponctuel spatial dont une réalisation est donnée par Z_k à l'itération k , sur un espace d'observation discret.

Le problème d'estimation du système linéaire stochastique à dimension variable est résolu de manière optimale mais non implémentable par le Filtre Bayésien Optimal (FBO) [Mahler 2006, Mahler 2003] qui estime de manière récursive la densité de probabilité jointe π_k sur un espace donné V_k d'un ensemble d'état X_k à l'instant k en deux étapes, prédiction (équation (1.64)) et estimation (équation (1.65)). Ainsi, connaissant la séquence de toutes les mesures \mathbf{Z}^k et conformément à [Vo 2007], la densité de probabilité jointe $\pi_{k+1|k}$ est prédite telle que :

$$\pi_{k+1|k}(X_{k+1}|\mathbf{Z}^k) = \int_{V_k} f_{k+1|k}(X_{k+1}|X_k) \cdot \pi_k(X_k|\mathbf{Z}^k) dX_k \quad (1.64)$$

où $f_{k+1|k}(X_{k+1}|X_k)$ est le modèle de transition d'un état k à $k+1$ multicible et π_k la densité de probabilité jointe *a posteriori*.

Puis, connaissant la séquence des mesures \mathbf{Z}^{k+1} jusqu'à l'itération $k + 1$, la densité de probabilité jointe est mise à jour telle que :

$$\pi_{k+1} \left(X_{k+1} | \mathbf{Z}^{k+1} \right) = \frac{g_{k+1} (Z_{k+1} | X_{k+1}) \cdot \pi_{k+1|k} (X_{k+1} | \mathbf{Z}^k)}{\int g_{k+1} (Z_{k+1} | X) \cdot \pi_{k+1|k} (X | \mathbf{Z}^k) dX} \quad (1.65)$$

avec $g_{k+1} (Z_{k+1} | X_{k+1})$ la vraisemblance multicible de l'ensemble des mesures Z_{k+1} à l'instant $k + 1$.

Concernant le calcul de l'estimateur, plusieurs solutions sont envisageables illustrées dans le cas monocible pour plus de clarté par la figure 1.23. Avec le Maximum *a posteriori* (MAP), l'étape d'estimation de $\hat{X}_{k+1|k+1}$ se fait en prenant l'argument maximum de la densité de probabilité jointe estimée $\pi_{k+1} (X_{k+1} | \mathbf{Z}^{k+1})$, tel que :

$$\hat{X}_{k+1|k+1}^{MAP} = \arg \sup_X \pi_{k+1} (X | \mathbf{Z}^{k+1}) \quad (1.66)$$

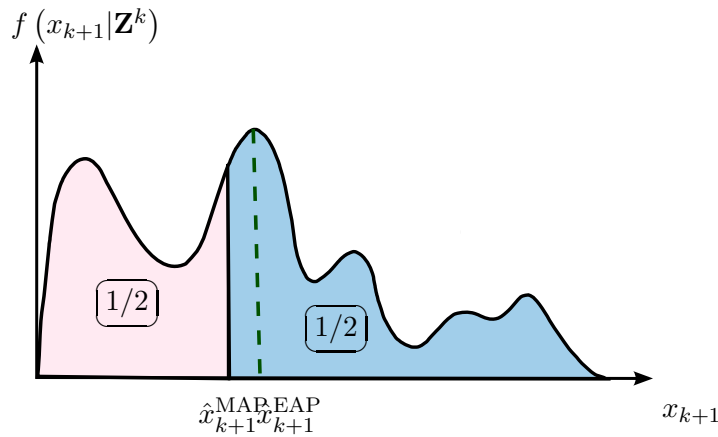


Fig. 1.23 – Différents estimateurs d'état - illustration pour une cible

L'estimation peut également être déterminée en utilisant une méthode du type *Expected A Posteriori* (EAP) autrement dit l'estimation est définie comme la valeur attendue *a posteriori* :

$$\hat{X}_{k+1|k+1}^{EAP} = \int X \pi_{k+1} (X | \mathbf{Z}^{k+1}) \delta X \quad (1.67)$$

1.4.3.2 Différentes philosophies

La problématique de pistage multicible peut être vue de deux manières. Sachant que l'espace d'état des cibles est continu,

- soit on discrétise immédiatement l'espace d'état et on considère l'état de chaque cible individuellement,
- soit on considère l'ensemble des cibles comme une variable multimodale et on la discrétise au dernier moment afin de fournir des estimations de l'état des cibles.

Les trois approches retenues, que nous présentons maintenant, sont des déclinaisons de ces « visions ».

- La première approche présentée est également la plus récente. Il s’agit du filtre CPHD (Cardinalized Probability Hypothesis Density) (*cf.* Partie 1.4.4). L’idée principale est de considérer l’état du système comme un ensemble fini aléatoire de cibles sur une surface donnée et d’étudier la densité de probabilité jointe de cet ensemble. En effet, le moment du premier ordre de cette densité fournit la position des pics et donc des cibles potentielles. De plus, la cardinalité de l’ensemble est également estimée à chaque itération. Depuis le début des années 2000, différentes formes implémentables pour ce filtre existent (un bon résumé des différentes versions de l’algorithme est proposé dans l’article de Vo : [Vo 2006a]) et fournissent des résultats très encourageants, notamment pour l’évaluation du nombre de cibles à chaque instant.
- La deuxième approche regroupe l’ensemble des techniques dites de « Monte-Carlo ». Appelée aussi filtrage particulaire, le principe du filtrage particulaire est de générer un nombre suffisant de particules pour simuler la densité de probabilité jointe de l’ensemble des cibles (*cf.* Partie 1.4.5). Différentes approches sont alors envisageables qui sont des déclinaisons des deux visions présentées pour le pistage multicible.
- La troisième approche consiste à discrétiser l’espace d’état du système et à considérer le cas de chaque cible individuellement. Ainsi, les étapes de prédiction (équation (1.68)) et estimation (équation (1.69)) du FBO s’écrivent :

$$\pi_{k+1|k}(x_{k+1}|\mathbf{Z}^k) = \int f_{k+1|k}(x_{k+1}|x_k) \pi_k(x_k|\mathbf{Z}^k) dx_k \quad (1.68)$$

$$\pi_{k+1}(x_{k+1}|\mathbf{Z}^{k+1}) = \frac{g_{k+1}(Z_{k+1}|x_{k+1}) f(x_{k+1}|\mathbf{Z}^k)}{\int g_{k+1}(Z_{k+1}|x) \cdot \pi_{k+1|k}(x|\mathbf{Z}^k) dx} \quad (1.69)$$

Le problème à résoudre consiste à trouver l’estimateur $\hat{x}_{k|k,j}$ de l’état $x_{k,j}$ de la cible j à l’itération k , en prenant en compte toutes les mesures \mathbf{Z}^k jusqu’à k , ainsi que l’incertitude ou covariance associée $P_{k|k,j}$, à partir de la séquence des mesures \mathbf{Z}^k .

$$\hat{x}_{k|k,j} = \mathbb{E} [x_{k,j}|\mathbf{Z}^k] \quad (1.70)$$

$$P_{k|k,j} = \mathbb{E} [(x_{k,j} - \hat{x}_{k|k,j})(x_{k,j} - \hat{x}_{k|k,j})^T | \mathbf{Z}^k] \quad (1.71)$$

Le filtre de Kalman, dont les équations sont décrites dans [Kalman 1960, Bar-Shalom 1993], permet de construire récursivement et de manière optimale la solution de ce problème dans un cas linéaire gaussien.

Cependant dans un cas multicible, avec cette première approche, le cœur du problème réside dans l’initialisation des pistes, dans l’association des mesures aux pistes et dans l’établissement de la vraisemblance de l’état prédit sachant les mesures. Plusieurs techniques sont envisageables. Dans le cas le plus simple ($P_d \approx 1$, $\beta_{fa} \approx 0$) chaque cible est associée à la mesure la plus probable (*cf.* 1.4.6.1). Pour gérer l’initialisation des pistes et les fausses alarmes, une autre approche considère toutes les hypothèses d’association des mesures aux pistes (*cf.* MHT 1.4.6.3). Finalement, en présence de nombreuses fausses alarmes, une dernière considère qu’une piste peut-être associée à plusieurs mesures et pondère l’estimation par la vraisemblance de chaque mesure associée (JPDAF *cf.* 1.4.6.4).

Par la suite, nous décrivons plus précisément les approches sélectionnées.

1.4.4 Le filtre PHD

1.4.4.1 Principe

Un Ensemble Fini Aléatoire (EFA) ou Random Finite Set (RFS) est un ensemble fini de variables aléatoires continues dont la cardinalité est également une variable aléatoire. Il est caractérisé par une distribution de probabilités discrètes et une famille de densités de probabilités jointes.

La dynamique des cibles est ainsi modélisée comme un RFS tel que :

$$X_k = \left[\bigcup_{\zeta \in X_{k-1}} S_{k|k-1}(\zeta) \right] \cup \left[\bigcup_{\zeta \in X_{k-1}} B_{k|k-1}(\zeta) \right] \cup \sigma_k \quad (1.72)$$

où $S_{k|k-1}(\zeta)$ est le RFS des cibles survivantes issues des états précédents ζ à l'itération $k-1$, $B_{k|k-1}(\zeta)$ est le RFS des cibles non résolues issues des états précédents ζ à l'itération $k-1$ et σ_k est le RFS modélisant les cibles naissantes.

De la même façon, les mesures issues du capteur peuvent être modélisées par un RFS tel que :

$$Z_k = \left[\bigcup_{x \in X_k} \tilde{Z}_k(x) \right] \cup K_k \quad (1.73)$$

où $\tilde{Z}_k(x)$ est le RFS des mesures issues des cibles x à l'itération k et K_k est le RFS des fausses alarmes à l'itération k .

1.4.4.2 Densité de Probabilités (Probability Hypothesis Density : PHD)

Le PHD (Probability Hypothesis Density) désigne la fonction d'intensité d'un RFS X définie sur l'espace géométrique \mathcal{X} . Cette notion a été introduite par Mahler [Mahler 2003] qui définit le PHD, appelé aussi fonction d'intensité, comme étant le moment du premier ordre de la densité jointe d'un ensemble de cibles *a posteriori*. Finalement, nous désignons donc le PHD comme étant une fonction non négative v qui a la propriété suivante sur n'importe quel espace fini $V \subseteq \mathcal{X}$:

$$\mathbb{E}[|X \cap V|] = \int_V v(x) dx \quad (1.74)$$

où $|X \cap V|$ représente le nombre de cibles sur l'espace V et $v(x)$ la fonction d'intensité en un point x . Finalement, le concept de fonction d'intensité est illustré par la figure 1.24.




Fig. 1.24 – Évolution de la fonction d'intensité de $k-1$ à k - Aux instants $k-1$ et k , on observe 4 pics d'intensité correspondant à des pistes potentielles.

La fonction d'intensité *a priori* $v_{k|k-1}$ de l'ensemble des cibles X_k à l'itération k peut être définie à partir de la fonction d'intensité *a posteriori* $v_{k-1|k-1}$ de l'itération précédente $k-1$. L'équation de prédiction devient :

$$v_{k|k-1}(x) = \left(\int P_s(\zeta) \cdot f_{k|k-1}(x|\zeta) \cdot v_{k-1}(\zeta) d\zeta \right) + \gamma_k(x) \quad (1.75)$$

avec $P_s(\zeta)$ la probabilité de survie d'une cible ayant l'état précédant ζ , $f_{k|k-1}(\cdot|\zeta)$ est la fonction de transition d'une cible connaissant son état précédent ζ et $\gamma_k(x)$ est la fonction d'intensité de naissance des nouvelles cibles.

Finalement, connaissant l'ensemble des mesures Z_k à l'itération k , la fonction d'intensité de l'ensemble des cibles peut être estimée de la manière suivante :

$$v_{k|k}(x) = (1 - P_d)v_{k|k-1}(x) + \sum_{z \in Z_k} \frac{P_d \cdot g(z|x)v_{k|k-1}(x)}{\kappa_k(z) + \int P_d \cdot g(z|\zeta)v_{k|k-1}(\zeta) d\zeta} \quad (1.76)$$

ntant où $g(z|x)$ est la vraisemblance d'une mesure z connaissant l'état d'une cible x et $\kappa_k(z)$ est la fonction d'intensité du bruit. Celle-ci est supposée uniforme sur la zone d'observation et sa cardinalité est modélisée par une loi de Poisson comme décrit dans l'équation (1.7).

Cette représentation permet de modéliser la densité de probabilité jointe de l'ensemble fini aléatoire des cibles en prenant en compte les non-détections et les fausses alarmes. L'avantage majeur de cette approche est qu'une cible n'est pas formellement associée à une ou plusieurs mesures : le problème d'association des données est donc sans objet. Néanmoins, la cardinalité de X_k , exprimée en (1.74), est modélisée par une loi de Poisson. Cela conduit à des problèmes de stabilité pour l'estimation du nombre de cibles lorsque la probabilité de détection diminue ou le nombre de fausses alarmes augmente comme montré par Erdinc *et al.* [Erdinc 2005]. Le filtre Cardinalized Probability Hypothesis Density (CPHD), qui peut être vu comme une généralisation du filtre PHD, propose de propager conjointement la distribution du nombre de cibles pour pallier cette faiblesse.

1.4.4.3 Cardinalité de la distribution de probabilité jointe (Cardinalized Probability Hypothesis Density : CPHD)

Le filtre Cardinalized Probability Hypothesis Density a été proposé pour la première fois par Ronald Mahler [Mahler 2006, Mahler 2007b, Mahler 2007a] en 2006, suite à un article écrit par Erdinc [Erdinc 2005] qui suggère que les faiblesses d'estimation du nombre de cibles du filtre PHD était dûes à l'utilisation uniquement du moment du premier ordre de la densité de probabilité jointe. L'idée générale du CPHD est donc de propager conjointement à la fonction d'intensité v_k , l'incertitude sur l'estimation du nombre de cibles présentes sur la zone d'observation (*i.e.* la distribution de probabilité du nombre de cibles). En effet, il est possible de prédire la probabilité $p_{k|k-1}(n)$ d'avoir n cibles à l'itération k en connaissant la probabilité $p_{k-1|k-1}(n)$ qu'il y avait d'en avoir n à l'itération $k-1$, $P_\Gamma(j)$, la probabilité d'avoir j cibles naissantes et $P_S(j)$ la probabilité d'avoir j cibles survivantes. Finalement, la probabilité d'avoir n cibles est prédite en considérant l'ensemble des hypothèses possibles pour ces n cibles sachant qu'une cible peut être une cible naissante ou une cible survivante :

$$p_{k|k-1}(n) = \sum_{j=0}^n P_\Gamma(n-j) \cdot P_S(j) \quad (1.77)$$

où $P_\Gamma(n - j)$ désigne la probabilité de naissance de $n - j$ cibles.

La probabilité $P_S(j)$ d'avoir j cibles survivantes à l'itération k est également calculée en considérant l'ensemble des hypothèses d'avoir eu entre j et une infinité de cibles à l'itération précédente. Cela revient à considérer les probabilités qu'un certain nombre de cibles n'aient pas survécues entre les itération k et $k + 1$. Cette probabilité est calculée en utilisant P_s la probabilité de survie d'une cible et la fonction génératrice G de la densité de probabilités du nombre de cibles p_k

Comme décrit dans [Mahler 2007a, Mahler 2006, Vo 2007], il vient :

$$P_S(j) = \frac{1}{j!} G_{k-1}^{(j)} (1 - \langle P_s, \bar{v}_{k-1} \rangle) \langle P_s, \bar{v}_{k-1} \rangle^j \quad (1.78)$$

où $G_{k-1}^{(l)}$ représente la dérivée $j^{\text{ème}}$ de G_{k-1} et \bar{v}_{k-1} la densité de probabilité normalisée $\bar{v} = v / \langle 1, v \rangle$

Par ailleurs, le produit scalaire de deux fonctions continues à valeurs sur V est calculé tel que :

$$\langle a, b \rangle = \int_{\forall x \in V} a(x)b(x)dx \quad (1.79)$$

Par conséquent, la probabilité d'avoir une cible survivante peut s'écrire sous la forme d'un produit scalaire tel que :

$$\langle P_s, \bar{v}_{k-1} \rangle = \int_{\forall x \in V} P_s(x)v_{k-1}(x)dx \quad (1.80)$$

Finalement, sachant que la dérivée $j^{\text{ème}}$ de G_{k-1} s'écrit sous la forme :

$$G_{k-1}^{(j)}(z) = \sum_{l=j}^{\infty} P_j^l \cdot p_{k-1}(l) \cdot z^{l-j} \quad (1.81)$$

On peut alors écrire la probabilité d'avoir eu des cibles non survivantes comme :

$$\frac{1}{j!} G_{k-1}^{(j)} (1 - \langle P_s, \bar{v}_{k-1} \rangle) = \sum_{l=j}^{\infty} \frac{P_j^l}{j!} \cdot p_{k-1}(l) \cdot (\langle 1 - P_s, \bar{v}_{k-1} \rangle) \quad (1.82)$$

Finalement, en remplaçant dans l'équation (1.77), on obtient :

$$p_{k|k-1}(n) = \sum_{j=0}^n P_\Gamma(n - j) \sum_{l=j}^{\infty} \frac{P_j^l}{j!} \cdot p_{k-1}(l) \cdot (1 - \langle P_s, \bar{v}_{k-1} \rangle) \langle P_s, \bar{v}_{k-1} \rangle^j \quad (1.83)$$

$$p_{k|k-1}(n) = \sum_{j=0}^n P_\Gamma(n - j) \sum_{l=j}^{\infty} C_j^l \frac{\langle P_s, v_{k-1} \rangle^j \langle 1 - P_s, v_{k-1} \rangle^{l-j}}{\langle 1, v_{k-1} \rangle^l} p_{k-1}(l) \quad (1.84)$$

où C_j^l désigne le coefficient binomial de paramètre (j, l) avec $j \leq l$.

L'étape de mise à jour de la densité de probabilité du nombre de cibles est réalisée en utilisant la formule de Bayes :

$$p_{k|k}(n) = \frac{\mathcal{L}(Z_k|n)}{\mathcal{L}(Z_k)} p_{k|k-1}(n) \quad (1.85)$$

où $\mathcal{L}(Z_k|n)$ est la vraisemblance du jeu de mesures sachant qu'il y a n cibles, et $\mathcal{L}(Z_k)$ est la vraisemblance du jeu de mesures. Cette expression peut également être écrite sous la forme suivante :

$$p_{k|k}(n) = \frac{\Upsilon_k^0[v_{k|k-1}, Z_k](n) \cdot p_{k|k-1}(n)}{\langle \Upsilon_k^0[v_{k|k-1}, p_{k|k-1}] \rangle} \quad (1.86)$$

où $\langle \Upsilon_k^0[v_{k|k-1}, p_{k|k-1}] \rangle$ est une constante de normalisation et $\Upsilon_k^0[v_{k|k-1}, p_{k|k-1}](n)$ représente la vraisemblance du jeu de mesures Z_k par rapport à l'intensité prédite $v_{k|k-1}$ en supposant qu'il y ait n cibles. Elle se calcule comme étant la somme de toutes les hypothèses possibles pour une mesure sachant qu'une mesure peut être soit une fausse alarme soit issue d'une cible et qu'une cible est détectée avec la probabilité P_d . Comme donné en [Vo 2007], $\forall n \in \mathbb{N}$,

$$\Upsilon_k^u[v, Z](n) = \sum_{j=0}^{\min(|Z|, n)} (|Z|-j)! P_\kappa(|Z|-j) \cdot \left[P_{j+u}^n \frac{\langle 1 - P_d, v \rangle^{n-(j+u)}}{\langle 1, v \rangle^n} \right] \cdot e_j(\Xi_k(v, Z)) \quad (1.87)$$

où $P_\kappa(n)$ est la probabilité d'avoir n fausses alarmes et e_j est la fonction symétrique élémentaire de l'ensemble $\Xi_k(v, Z)$ (cf. Partie 2.3.6.2 pour le calcul et le sens de la fonction symétrique élémentaire). L'ensemble $\Xi_k(v, Z)$ est une mesure de la vraisemblance des mesures Z par rapport à v telle que :

$$\Xi_k(v, Z) = \{ \langle v, \psi_{k,z} \rangle, z \in Z \} \quad (1.88)$$

La variable $\psi_{k,z}$ est une mesure de vraisemblance de la mesure z par rapport à l'état prédit x :

$$\psi_{k,z}(x) = \frac{\langle 1, \kappa_k \rangle}{\kappa_k(z)} g(z|x) P_d \quad (1.89)$$

avec $g(z|x)$ la vraisemblance de z par rapport à x et $\frac{\kappa_k(z)}{\langle 1, \kappa_k \rangle}$ est la densité de fausses alarmes.

Finalement, la fonction symétrique élémentaire $e_j(\Xi_k(v, Z))$ sera maximale pour j égal au nombre de mesures associées réellement à une cible (*i.e.* dont la vraisemblance par rapport à v est forte).

Sur le même principe, nous pouvons également définir l'équation de mise à jour de la fonction d'intensité. Cette expression est composée de deux parties. La première concerne l'ensemble des hypothèses de non détection : l'état prédit est conservé et la valeur de l'intensité diminue en fonction de la probabilité de détection et de $\Upsilon_k^1[v_{k|k-1}, Z_k]$ la vraisemblance du jeu de mesures sachant qu'il y a n cibles et que au moins l'une d'elle est non détectée. La deuxième partie représente l'intensité de mise à jour en considérant toutes les hypothèses d'association entre les cibles détectées à l'itération $k-1$ et les mesures. Cela s'écrit de la manière suivante :

$$v_{k|k}(x) = \frac{\langle \Upsilon_k^1[v_{k|k-1}, Z_k], p_{k|k-1} \rangle}{\langle \Upsilon_k^0[v_{k|k-1}, Z_k], p_{k|k-1} \rangle} (1 - P_d) v_{k|k-1} + \sum_{z \in Z_k} \frac{\langle \Upsilon_k^1[v_{k|k-1}, Z_k \setminus \{z\}], p_{k|k-1} \rangle}{\langle \Upsilon_k^0[v_{k|k-1}, Z_k], p_{k|k-1} \rangle} \psi(x) v_{k|k-1}(x) \quad (1.90)$$

où $Z_k \setminus \{z\}$ représente l'ensemble des mesures Z privé de la mesure z .

1.4.4.4 Différentes versions implémentables

Comme la propagation du PHD implique l'utilisation de plusieurs intégrales, il n'existe pas de forme littérale pour représenter la fonction d'intensité *a posteriori*. Cependant, différentes versions implémentables sont possibles.

La première est une approche particulière. Cette méthode est appelée *Particle Probability Hypothesis Density* (PPHD) ou encore *Sequential Monte Carlo Probability Hypothesis Density* (SMCPHD) et a été utilisée pour de nombreuses applications de pistage [Lin 2006, Vo 2003, Vo 2005, Schubert 2004, Clark 2006a, Clark 2007, Sidenbladh 2003, Maggio 2007]. Elle peut être également combinée avec le CPHD.

La deuxième utilise les mélanges de gaussiennes. Il est possible de réaliser l'implémentation sans la version cardinalisée (GM-PHD : Gaussian Mixture Probability Hypothesis Density) [Vo 2006b] ou avec la version cardinalisée (GM-CPHD : Gaussian Mixture Cardinalized Probability Hypothesis Density) [Vo 2007]. Le détail de l'implémentation du GM-CPHD est donnée dans la partie 2.3.

Il faut noter que, dans leur version, originale, ces versions implémentables permettent d'estimer récursivement la fonction d'intensité v_k . Néanmoins, elles ne proposent pas de labellisation des pics d'intensité. Par conséquent, les pistes ne sont directement identifiées. Bien que le problème soit peu relaté dans la littérature, cela a également des conséquences au niveau de l'estimation de la vitesse.

1.4.5 Le filtrage particulaire

De nombreux travaux ont été réalisés dans le domaine du filtrage particulaire appelé aussi *Bootstrap filter* ou technique de Monte-Carlo. Il s'agit d'une technique d'estimation basée sur la simulation : la densité de probabilité *a posteriori* est approximée par un jeu de particules suivant une loi *a priori*. Il s'agit d'une approche efficace dans le cadre du pistage mono et multicible. De plus, cette approche apporte l'avantage de s'affranchir des conditions de linéarité de l'équation d'état du système défini en (1.55) et constitue ainsi une alternative à l'EKF (Extended Kalman Filter) [Jazwinski 1970] et l'UKF (Unscented Kalman Filter) [Julier 1997].

Par ailleurs, le filtrage particulaire est particulièrement utilisé dans le cadre du pistage de groupe de cibles [Gordon 1993, Gordon 1996, Pollard 2008a], car il s'agit d'une alternative intéressante pour les cas non-linéaires non-gaussiens, ce qui peut être le cas avec des cibles proches, puisque, comme illustré par la figure 1.25, les mesures peuvent être non-indépendantes et suivre une loi multimodale.




Fig. 1.25 – Illustration du problème de non gaussianité de mesures proches - (a) mesures éloignées = deux gaussiennes indépendantes - (b) mesures proches : loi multimodale




Fig. 1.26 – Illustration du filtrage particulaire classique

L'ensemble des approches de type Monte-Carlo est particulièrement bien expliqué dans le livre écrit par Ristic, Arulampalam et Gordon [Ristic 2004].

1.4.5.1 Cas monocible

Le principe du filtrage particulaire monocible est de simuler aléatoirement la densité de probabilité d'une cible par un ensemble de N^p particules qui se déplacent selon des réalisations indépendantes à partir de l'équation d'état. Ces particules sont ensuite pondérées en fonction de leur cohérence avec les observations.

Ainsi, il s'agit de créer N^p échantillons sensés représenter la densité de probabilité *a posteriori* $f(x_k|\mathbf{Z}^k)$ de la cible telle qu'elle puisse être écrite sous la forme :

$$f(x_k|\mathbf{Z}^k) \approx \sum_{p=1}^{N^p} q_k^p \delta(x_k - x_k^p) \tag{1.91}$$

où δ est une distribution de Dirac et q_k^p le poids d'une particule p .

Ainsi, comme cela est illustré par la figure 1.26, si l'équation d'observation suit une loi gaussienne, alors la densité de probabilité de l'état conditionnellement aux mesures peut être estimée à partir d'un échantillon de particules initiales.

Étape 0 : Initialisation du jeu de particules : N^p particules sont générées autour d'une position initiale x_0 à partir d'un bruit blanc gaussien centré de covariance P_0 telles que :

$$\forall p \in \{1, \dots, N^p\}, \quad x_0^p = \mathcal{N}(x_0, P_0) \tag{1.92}$$

Le poids q_k^p d'une particule p est initialisé à $1/N^p$.

Étape 1 : Prédiction ou génération des N^p particules à l'itération k à partir des N^p particules à l'itération $k - 1$. Pour obtenir une approximation de la densité de probabilité de la cible *a priori* $f(x_{k|k-1}|Z_{k-1})$, les particules sont propagées selon la loi

d'évolution du système (possiblement selon (1.55)) par tirage indépendant du bruit ν_{k+1} .

Étape 2 : Calcul du poids. Le poids d'une particule est défini comme la vraisemblance du jeu de mesures Z_k à l'itération k par rapport à la position prédite de la particule telle que :

$$q_k^p = f(Z_k | x_{k|k-1}^p) \quad (1.93)$$

Étape 3 : Normalisation. Pour que le filtre reste cohérent, il est nécessaire que les poids remplissent la condition suivante :

$$\sum_{p=1}^{N_p} q_k^p = 1 \quad (1.94)$$

Une étape de normalisation des poids est donc réalisée.

Étape 4 : Rééchantillonnage. Cette étape est nécessaire pour éviter la dégénérescence du nuage de particules et donc la divergence du filtre. En effet, lors du tirage des particules, on ajoute du bruit, il est donc nécessaire de supprimer ponctuellement les particules les moins vraisemblables. Comme un nuage de particules est composé de particules de poids forts (celles qui portent réellement l'information) et de particules de poids faible, si le nombre effectif de particules (une mesure de l'information contenue dans le nuage calculée comme dans [Kong 1994, Doucet 2000]) est inférieur à un certain seuil, il faut éliminer les particules de poids faible et dupliquer les particules de poids fort.

Étape 5 : Estimation. Finalement, l'état estimé est une combinaison pondérée des états des différentes particules survivantes :

$$\hat{x}_{k|k} = \sum_{p=1}^{N_p} q_k^p \cdot x_k^p \quad (1.95)$$

$$P_{k|k} = \sum_{p=1}^{N_p} q_k^p \cdot (x_k^p - \hat{x}_{k|k}) \cdot (x_k^p - \hat{x}_{k|k})^T \quad (1.96)$$

Le cœur du problème réside encore une fois dans l'évaluation de la vraisemblance du jeu de mesures $f(Z_k | x_{k|k-1}^p)$. Dans un cas monocible, l'approche est souvent limitée à une approche du type plus proche voisin (*cf.* 1.4.6.1). Cependant, d'autres approches plus complexes pour prendre en compte la présence de fausses alarmes peuvent être envisagées et sont décrites dans la partie suivante consacrée à l'extension au cas multicible. L'autre enjeu est « à partir de combien de particules la simulation de la densité de probabilité de la cible est-elle jugée suffisamment proche de la réalité ? ».

1.4.5.2 Extension au cas multicible

Le principe du filtrage particulière dans le cas multicible est très similaire au cas monocible. Le vecteur d'état d'une particule X_k^p est défini comme la concaténation des vecteurs d'état des différentes cibles appelés partitions. Par conséquent, le nombre de cibles N est supposé connu et constant.

Ainsi, une particule s'écrit sous la forme :

$$X_k^p = [x_{k,1}^p, \dots, x_{k,N}^p]^T \quad (1.97)$$

En supposant que les mesures sont indépendantes, le poids d'une particule est alors calculé comme le produit des vraisemblances de chaque mesure z associée à chaque état prédit $\hat{x}_{k|k-1,i}^p$ tel que :

$$\begin{aligned} q_k^p &= f_k(Z_k | X_{k|k-1}^p) \\ &= \prod_{i=1}^{N_k} f(z | x_{k|k-1,i}^p) \end{aligned} \quad (1.98)$$

A travers cette modélisation du problème, deux enjeux apparaissent. Le premier concerne le rééchantillonnage : comment rééchantillonner efficacement le jeu de particules sans faire exploser la combinatoire. Le second réside dans l'évaluation de la vraisemblance du jeu de mesures par rapport à l'état prédit concaténé des différentes cibles $f(Z_k | X_{k|k-1}^p)$.

1. Rééchantillonnage. Si le rééchantillonnage est effectué sur le même principe que le filtre particulaire monocible, les particules de poids le plus fort sont dupliquées et les particules de poids le plus faible sont supprimées. Les différentes alternatives concernant la méthode de sélection des particules de poids fort (rééchantillonnage par importance, rééchantillonnage séquentiel) sont décrites en [Doucet 2000]. Ainsi, comme la vraisemblance des particules correspond au produit des vraisemblances des partitions, les particules conservées sont formées de partitions très vraisemblables et d'autres peu vraisemblables [Maskell 2002]. Concrètement, le problème est que pour pister N cibles en obtenant des performances de pistage équivalentes à celles obtenues avec le filtre particulaire monocible, il faut utiliser $N \times N^p$ particules ce qui est difficile à mettre en œuvre au niveau de la combinatoire.

Une solution, appelée Independent Partition Particle Filter (IPPF) [Orton 2002], consiste, lors de l'étape de rééchantillonnage, non pas à utiliser les particules les plus vraisemblables, mais à construire de nouvelles particules, en utilisant les partitions les plus vraisemblables. Ainsi, avec cette approche, il n'est pas nécessaire d'augmenter le nombre de particules en fonction du nombre d'objets pistés. Cependant, il est nécessaire que les partitions correspondant aux différents objets soient indépendantes.

Comme la notion d'indépendance des cibles intervient couramment, il peut être intéressant d'utiliser des méthodes du type *k-means* afin de rendre indépendantes les différentes partitions. [Lloyd 1982, Kanungo 2002] Le principe, illustré par la figure 1.27, est de bien séparer les trois partitions (en vert, rouge et bleu) en trois groupes indépendants.

2. Évaluation de la vraisemblance ou mise en correspondance des particules avec les mesures.

Plusieurs solutions sont envisageables.

Considérer la densité de probabilité jointe Dans de récents travaux, Kastella propose de considérer la vraisemblance d'une mesure par rapport à la densité de probabilité jointe de l'ensemble des cibles [Kastella 1997, Kreucher 2003, Kreucher 2005] occultant ainsi le problème d'association des mesures aux cibles. Il propose ainsi un nouvel algorithme appelé JMPD pour *Joint Multitarget*

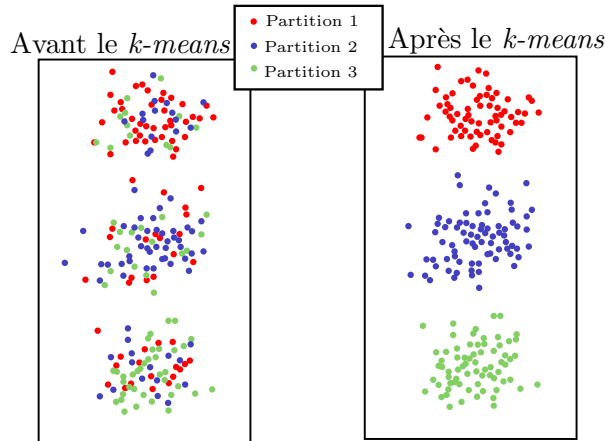


Fig. 1.27 – Un exemple de clustering avec le *k-means*

Probability Density très complet qui estime le nombre de cibles et prend en compte la probabilité d'avoir de nouvelles cibles. Concernant le calcul de la vraisemblance, le principe est le suivant :

$$f(Z_k|X_{k|k-1}^p) = \prod_{i=1}^{m_k} f(z_{k,i}|X_{k|k-1}^p) \quad (1.99)$$

Ensuite, la vraisemblance de chaque mesure est calculée selon les deux cas : les partitions sont indépendantes ou les partitions ne sont pas indépendantes. Auxquels cas, l'IPPF est utilisé ou une autre méthode appelée CPPF (*Coupled Partition Particle Filter*) spécifiquement adaptés aux partitions non-indépendantes. Finalement, l'auteur ouvre avec son algorithme, une passerelle vers l'approche de type PHD, qui, en considérant l'état des cibles comme un processus ponctuel, étudie également la vraisemblance des mesures par rapport à la densité de probabilité jointe des cibles. En effet, bien qu'écrite dans un formalisme différent, l'implémentation est finalement très proche de celle du filtre PHD en version particulière.

Approche du plus proche voisin : Chaque cible est associée à la mesure la plus proche ou la plus vraisemblable notée z et finalement :

$$\begin{aligned} f(Z_k|X_{k|k-1}^p) &= \prod_{i=1}^{N_k} f(z|\hat{x}_{k|k-1,i}^p) \\ &= \prod_{i=1}^{N_k} \frac{1}{\sqrt{|2\pi R_k|}} \exp\left(-\frac{1}{2}\left(z - \hat{x}_{k|k-1,i}^p\right)^T (R_k)^{-1} \left(z - \hat{x}_{k|k-1,i}^p\right)\right) \end{aligned} \quad (1.100)$$

Cette solution revient à discrétiser l'espace d'état des cibles et à considérer le cas de chaque cible individuellement.

Considérer toutes les hypothèses d'association possibles : Dans [Gordon 1997], Gordon propose de considérer toutes les hypothèses d'associations cibles/mesures et de pondérer la vraisemblance du jeu de mesures par la probabilité d'occurrence de cette hypothèse $P\{\mathcal{H}_i\}$ telle que :

$$f(Z_k|X_{k|k-1}^p) = \sum_{\mathcal{H}_i} f_k(Z_k|X_{k|k-1}^p, \mathcal{H}_i) P\{\mathcal{H}_i\} \quad (1.101)$$

Finalement, l'approche de Kyriakides [Kyriakides 2000] a un but similaire car elle définit des régions de contrainte afin de limiter les associations cibles/mesures possibles.

Association de type PDAF : Comme décrit dans [Isard 1998, Vermaak 2005, Karlsson 2001], il est possible de réaliser une association cibles/mesures de type PDAF [Bar-Shalom 1988], avec les mêmes désavantages qu'avec un filtre PDAF notamment le problème d'initialisation des pistes. Ainsi, le cas de chaque cible individuelle est considéré et la vraisemblance des mesures est telle que :

$$f(Z_k | x_{k|k-1,j}^p) = \beta_{k,j}^{(0)} + \sum_{i=1}^{m_{k,j}} \beta_{k,j}^{(i)} f_k(z_{k,i} | \hat{x}_{k|k-1,j}^p) \quad (1.102)$$

Échantillonneur de Gibbs : Dans [Hue 2000], Hue propose d'utiliser un échantillonneur de Gibbs afin d'estimer la probabilité d'association *a posteriori*. Les échantillons créés par l'échantillonneur de Gibbs sont également utilisés pour initialiser ou terminer des pistes.

1.4.6 Les méthodes de type Kalman

La troisième approche consiste à analyser le cas de chaque cible individuellement. La principale difficulté est alors d'associer les mesures aux cibles. Avant de décrire deux techniques basées sur ce principe (le MHT et le JPDAF), nous décrivons la technique de fenêtrage statistique qui est constamment utilisée afin de limiter le nombre de mesures associables à une cible.

1.4.6.1 Le fenêtrage statistique

Pour limiter le nombre de mesures $z_{k,i}$ à traiter par les algorithmes de pistage, une technique de sélection des mesures appelée fenêtrage statistique (*gating*) est réalisée [Sittler 1964]. Pour chaque cible, le fenêtrage consiste à délimiter, à partir de la position prédite d'une cible $\hat{x}_{k|k-1,j}$ et de sa covariance prédite associée $P_{k|k-1,j}$, un certain volume V de l'espace d'observation où la mesure de la cible a une forte probabilité P_g de se trouver. Les mesures statistiquement trop éloignées de la position prédite sont ainsi éliminées. Par exemple, dans l'exemple présenté en figure 1.22, la piste $\mathbf{T}_{k,1}$ ne peut être associée qu'à la mesure $z_{k,1}$, tandis que la piste $\mathbf{T}_{k,2}$ peut être associée aux trois mesures $z_{k,1}$, $z_{k,2}$ et $z_{k,3}$. Ces mesures sont validées, car elles appartiennent aux volumes de validation des pistes, représentées graphiquement par des ellipses.

Finalement, le test de validation pour la mesure $z_{k,i}$ s'obtient en imposant un seuil minimal à la densité de la mesure $f(z_{k,i} | \mathbf{Z}^{k-1})$ tel que :

$$\begin{cases} \text{Si } (z_{k,i} - \hat{x}_{k|k-1,j})^T P_{k|k-1,j}^{-1} (z_{k,i} - \hat{x}_{k|k-1,j}) < \gamma & z_{k,i} \text{ validée} \\ \text{Si } (z_{k,i} - \hat{x}_{k|k-1,j})^T P_{k|k-1,j}^{-1} (z_{k,i} - \hat{x}_{k|k-1,j}) > \gamma & z_{k,i} \text{ rejetée} \end{cases} \quad (1.103)$$

où $\hat{x}_{k|k-1,j}$ désigne la position prédite de la cible j et $P_{k|k-1,j}$ est défini en (1.71).

Plus de détails sur le calcul de γ et le fenêtrage statistique sont disponibles dans [Dezert].

1.4.6.2 Les méthodes du plus proche voisin

La méthode du plus proche voisin (Nearest Neighbor : NN) consiste à sélectionner pour chaque piste existante, la mesure la plus proche au sens de la norme \mathcal{L}_2 .

Cependant, ce procédé ne prend pas en compte l'imprécision sur les mesures et sur les estimations. Par conséquent, il est judicieux de choisir la mesure z telle que la probabilité d'association d'une piste $x_{k,j}$ à la mesure z soit maximale sur l'ensemble des mesures avec :

$$z = \underset{z_{k,i}}{\operatorname{argmax}} \{P_{as}(z_{k,i}, x_{k,j})\}_{i=1}^{m_{k,j}} \quad (1.104)$$

avec $m_{k,j}$ le nombre de mesures appartenant à la fenêtre de validation de $x_{k,j}$ et $P_{as}(z_{k,i}, \hat{x}_{k,j})$ la probabilité d'association de la mesure $z_{k,i}$ avec la cible $x_{k,j}$ telle que :

$$P_{as}(z_{k,i}, x_{k,j}) = \frac{1}{\sqrt{2\pi|R_{k,i} + P_{k,j}|}} \exp\left(-\frac{1}{2}(z_{k,i} - \mathbf{x}_{k,j})^T (R_{k,i} + P_{k,j})^{-1} (z_{k,i} - \mathbf{x}_{k,j})\right) \quad (1.105)$$

avec $R_{k,i}$ la matrice de covariance définie en (1.6).

Cependant, si une cible est non-détectée, la cible va être associée à une fausse alarme. Afin de limiter ce problème, un fenêtrage statistique tel que décrit dans la partie 1.4.6.1, est réalisé. Si la cible ne peut être associée à aucune mesure, alors l'état prédit devient l'état estimé.

Le principal avantage de cette méthode est sa simplicité de mise en œuvre. Cependant, elle reste très rudimentaire et ses performances décroissent avec des scénarios complexes en présence de fausses alarmes ou de cibles proches par exemple.

1.4.6.3 Le MHT

Principe L'approche à hypothèses multiples de pistage (Multiple Hypothesis Tracker : MHT) proposée par Reid en 1979 [Reid 1979] est dans son principe une extension de l'approche FBO (Filtre Bayésien Optimal) au cas multicible. Dans le MHT, l'ensemble des hypothèses sur l'origine des mesures est considéré. Ainsi, la probabilité *a posteriori* pour que chaque mesure fournie à l'instant k provienne

- soit d'une fausse alarme,
- soit d'une cible existante,
- soit d'une nouvelle cible,

est évaluée.

L'une des particularités du MHT est que le nombre de cibles n'est pas connu *a priori* contrairement au JPDAF. Le principe du MHT est donc de générer un ensemble d'hypothèses (arbre d'hypothèses) sur l'origine de chaque mesure disponible. La probabilité *a posteriori* de chaque hypothèse est calculée récursivement en tenant compte des détections manquantes, des fausses alarmes et de l'apparition de nouvelles cibles.

Les différentes hypothèses pour l'origine des mesures sont indexées avec le formalisme suivant :

0 : la mesure est une fausse alarme.

1/2 : la mesure provient d'une des deux pistes 1 ou 2 existantes. À noter que seule $z_{k,1}$ peut être associée à la piste \mathbf{T}_1^k .

3/4/5 : la mesure provient d'une nouvelle piste indexée par 3, 4 ou 5.

Ces différentes hypothèses peuvent être représentées par l'arborescence présentée en Figure 1.28 pour le scénario présenté en Figure 1.22. Ainsi, la mesure z_1 peut être soit une fausse alarme (indexée par 0), soit la continuité d'une des pistes 1 ou 2 (indexée par 1 et 2), soit le début d'une piste indexée par 3. La mesure z_2 peut être soit une fausse alarme (indexée par 0), soit la continuité de la piste 2, soit le début d'une nouvelle piste indexée alors par 4. Comme une piste ne peut être associée qu'à une mesure, lorsqu'on considère l'hypothèse où z_1 est la continuité de la piste 2, la mesure z_2 ne peut pas être la continuité de la piste 2. On réitère le procédé pour z_3 .

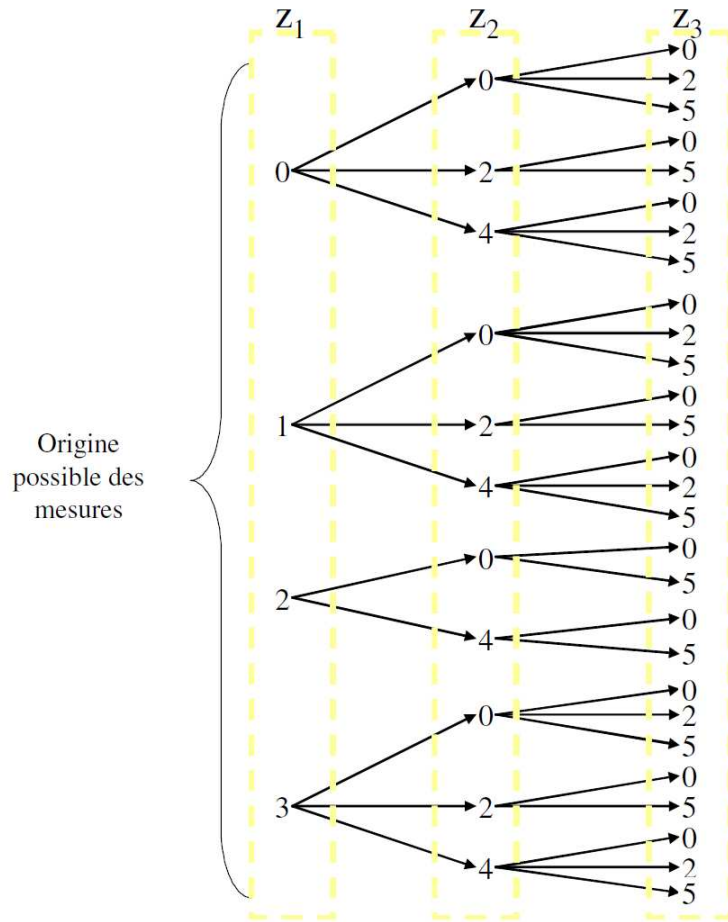


Fig. 1.28 – Arbre d'hypothèses du MHT - pour le scénario présenté en Figure 1.22

L'arborescence est construite en obéissant à certaines règles. Par exemple, le cas des cibles non-résolues n'est pas considéré. Ainsi, une mesure ne peut pas être associée à deux pistes dans le même scénario d'association. La matrice d'association A^{MHT} du scénario s'écrit finalement :

$$A^{\text{MHT}} = \begin{pmatrix} 0 & 1 & 2 & 3 & 0 & 1 & 3 & 0 & 1 & 2 & 3 & 0 & 1 & 3 & 0 & 1 & 3 & 0 & 1 & 2 & 3 & 0 & 1 & 3 & 0 & 1 & 2 & 3 \\ 0 & 0 & 0 & 0 & 2 & 2 & 2 & 4 & 4 & 4 & 4 & 0 & 0 & 0 & 4 & 4 & 4 & 0 & 0 & 0 & 0 & 2 & 2 & 2 & 4 & 4 & 4 & 4 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 2 & 2 & 2 & 2 & 2 & 2 & 5 & 5 & 5 & 5 & 5 & 5 & 5 & 5 & 5 & 5 & 5 \end{pmatrix} \tag{1.106}$$

où les lignes représentent les mesures et les colonnes représentent chaque nouvelle hypothèse d'association.

L'arbre des différents scénarios d'association est ensuite étendu à l'itération suivante $k + 1$ en générant de nouvelles hypothèses et cela de manière récursive. La taille de l'arbre croît donc de manière exponentielle. Dans notre exemple, pour 2 cibles et 3 mesures, 28 hypothèses d'association sont envisagées.

Sur ce principe, les enjeux du MHT sont doubles :

- Déterminer parmi l'ensemble des hypothèses lesquelles correspondent réellement à des cibles.
- Créer des heuristiques afin de supprimer des hypothèses pour limiter la croissance exponentielle de la matrice d'association.

Approche orientée piste (TOMHT) Généralement, dans le MHT usuel, les hypothèses d'association conjointes cumulées sont gérées en supprimant les hypothèses les plus invraisemblables et en combinant celles qui sont similaires. La métrique utilisée pour classer les hypothèses est simplement la probabilité associée aux scénarios d'association. C'est ici que l'algorithme à inférence bayésienne perd son optimalité par suppression des branches les moins probables mais ce sacrifice est nécessaire car il limite l'explosion de la combinatoire. Les nouvelles hypothèses sont générées à partir des hypothèses survivantes. À partir de la probabilité *a priori* sur chaque nouvelle hypothèse, et en éliminant et combinant les hypothèses filles, l'algorithme doit énumérer et évaluer un nombre très important d'hypothèses avec un MHT standard. En dépit de la suppression des hypothèses les moins probables, le problème reste critique dans un environnement multicible et riche en fausses alarmes.

Il existe donc différentes manières de gérer cet arbre d'hypothèses. L'alternative proposée par Blackman dans [Blackman 1986] consiste à réexaminer la manière dont les hypothèses sont formées et à reconsidérer la métrique de classement des scénarios d'association. Dans les approches proposées par Kurien [Kurien 1990] et Demos [Demos 1990], l'objectif est de réorganiser le MHT en partant cette fois-ci de la définition de la vraisemblance d'une piste et en propageant cette dernière aux différents scénarios d'association. L'idée est d'évaluer la continuité de chaque piste à chaque instant d'échantillonnage. Kurien propose une approche heuristique afin de classer la continuité des pistes en fonction de leur durée de vie, en termes de nombre de scans. Une piste est dite « native » si sa longueur est égale à un, « tentative » si sa longueur est supérieure ou égale à deux, « intermédiaire » si sa longueur est supérieure ou égale à trois et « confirmée » si la longueur de la piste est supérieure ou égale à quatre. En fonction du niveau de classification, une probabilité *a priori* est attribuée à chaque piste. En utilisant une approche bayésienne, la probabilité de chaque piste est évaluée en fonction de la vraisemblance. Il devient possible de séparer les différents scénarios d'association et d'évaluer la probabilité de ces derniers qui est calculée à partir de la probabilité de chaque piste. L'approche proposée par Demos quant à elle, classe les pistes à partir de leur fonction « score ». Partant des hypothèses suivantes,

- \mathcal{H}_1 , la mesure associée à la piste est originaire de la cible pistée,
- \mathcal{H}_0 , la mesure est soit une fausse alarme soit une nouvelle cible,

les auteurs définissent la fonction score comme le ratio entre la vraisemblance *a posteriori* de \mathcal{H}_1 et la vraisemblance *a posteriori* de \mathcal{H}_0 . Cette fonction permet d'évaluer la pertinence du scénario d'association. Il faut ensuite décider de la validation de l'une des deux hypothèses lorsque le test séquentiel de Wald est satisfait. Ce test de validité est présenté dans [Blackman 1986]. L'utilisation de ce test permet de différer le moment de prendre une décision. Cette approche est appelée branche structurée (Structure Branching : SB)

et son implémentation dans le MHT est présentée dans cette partie. La métrique utilisée dans l'approche SB est la fonction score cumulée. Le score cumulé d'une piste permet de calculer la probabilité globale de chaque piste afin de supprimer les pistes les moins probables. En supprimant certaines pistes avant la génération des hypothèses d'association, un grand nombre d'hypothèses invraisemblables ne sont jamais générées. C'est ce test qui sera utilisé tout au long du manuscrit.

Le synoptique de l'algorithme MHT retenu est proposé dans la figure 1.29. Les diffé-

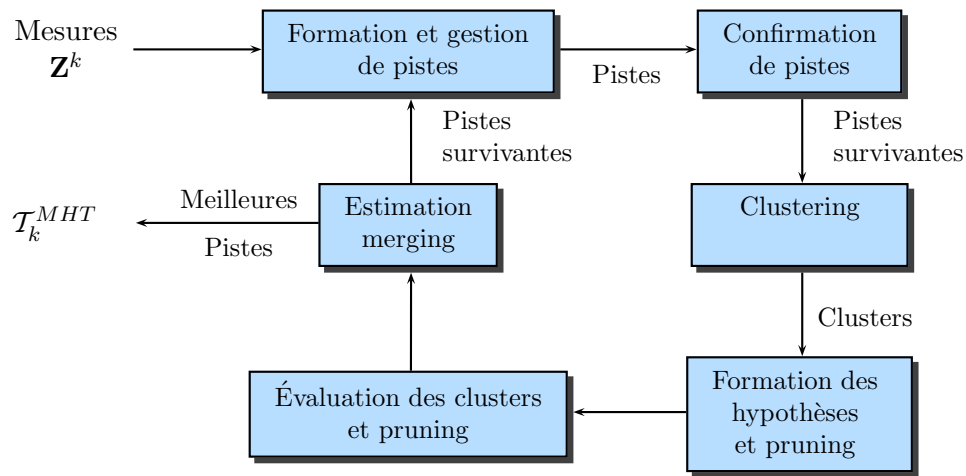


Fig. 1.29 – Schéma bloc du MHT

rentes étapes sont les suivantes :

Formation et gestion de pistes : Comme décrit dans la partie 1.4.6.3, après fenêtrage statistique, à partir des pistes existantes, un arbre d'hypothèses est constitué pour envisager toutes les hypothèses d'associations des mesures.

Confirmation des pistes : Dans l'approche de Demos [Demos 1990], la classification des pistes repose sur un test séquentiel basé sur le ratio des probabilités appelé test de Wald [Wald 2004]. Une piste peut être confirmée, en attente de confirmation ou supprimée. À partir de la valeur du score $s_{k,j}$ d'une piste $\mathcal{T}_{k,j}$, la classification d'une piste s'obtient à partir du test suivant :

$$\begin{aligned}
 s_{k,j} &\geq \gamma_2 && \text{piste confirmée} \\
 \gamma_1 &\leq s_{k,j} \leq \gamma_2 && \text{piste non confirmée} \\
 s_{k,j} &\leq \gamma_1 && \text{piste supprimée}
 \end{aligned} \tag{1.107}$$

avec γ_1 et γ_2 des seuils dont l'expression peut être retrouvée dans [Blackman 1986].

Clustering : Génération d'une liste de pistes qui interagissent entre elles. Cette opération est transitive : si $\mathcal{T}_{k,1}$ et $\mathcal{T}_{k,2}$ interagissent et si $\mathcal{T}_{k,2}$ et $\mathcal{T}_{k,3}$ interagissent, alors le cluster est formé des pistes $\mathcal{T}_{k,1}$, $\mathcal{T}_{k,2}$ et $\mathcal{T}_{k,3}$.

Formation des hypothèses et pruning : Pour chaque « cluster », l'algorithme génère toutes les hypothèses d'association au temps courant. Ces hypothèses sont obtenues

à partir d'un ensemble de pistes « compatibles ». Après le calcul des probabilités associées à chaque hypothèse, vient la phase d'élimination des hypothèses les moins probables (étape de « *pruning* »). Une approche dite « *N-scan pruning* » présentée dans [Blackman 1999], peut-être utilisée pour éliminer les branches de l'arbre les moins probables.

Évaluation des clusters : La probabilité globale d'une piste est obtenue à partir de la somme des probabilités de chaque hypothèse d'association contenant la piste. Les pistes dont la probabilité globale est inférieure à un seuil sont éliminées.

Estimation et merging : Les états estimés ainsi que leur covariance sont obtenus à partir des pistes survivantes. Il devient important à cette étape de combiner (phase de « *merging* ») les pistes dont les états estimés sont relativement proches. Les hypothèses de probabilité les plus faibles étant supprimées, les hypothèses d'association dont les « effets » sont similaires peuvent encore être combinées. Deux hypothèses ont un effet similaire lorsque le nombre de pistes existantes à l'itération courante est le même et lorsque les états estimés des cibles sont proches statistiquement. Les méthodes permettant de décider si deux pistes sont effectivement « similaires », ont fait l'objet de nombreux travaux [Blackman 1986, Williams 2003].

Ainsi, à l'initialisation, chaque mesure est considérée comme une piste naissante potentielle, ce qui permet une initialisation efficace des pistes. De même, les différentes étapes de pruning permettent de modéliser la fin d'une piste. En ce qui concerne la gestion de cibles proches, bien que l'étape de clustering soit sensée gérer spécifiquement cette problématique, la présence d'un groupe trop important de cibles proches fait baisser les performances. Par ailleurs, lorsque le nombre de fausses alarmes est trop important, les performances décroissent.

Cette partie est inspirée des travaux de thèse de Benjamin Pannetier. Par conséquent, plus de détails sont disponibles dans [Pannetier 2006a]-chap 1.

1.4.6.4 Le filtre JPDA

Au contraire du MHT, le filtre JPDA considère qu'une cible peut être associée à plusieurs mesures. Il est donc plus adapté à la problématique de fausses alarmes.

Cas monocible : le PDAF Le filtre JPDAF (Joint Probabilistic Data Association Filter) est la version multicible du filtre PDA (Probabilistic Data Association Filter) [Kirubarajan 2004]. Le principe du PDAF est qu'il utilise pour l'étape d'association des mesures aux cibles, l'ensemble des mesures $Z_{k,j}$, de taille $m_{k,j}$, appartenant à la fenêtre de validation d'une cible j pondérées par leur probabilité d'association.

Les différents événements $\theta_{k,j}$ concernant les mesures $Z_{k,j}$ appartenant à la fenêtre de validation de la cible j sont notés de la façon suivante :

$$\theta_{k,j} = \begin{cases} \{z_{k,i} \text{ provient de la cible } j\} & \forall i = 1, \dots, m_{k,j} \\ \{\text{toutes les mesures sont des FA}\} & i = 0 \end{cases} \quad (1.108)$$

Ainsi, l'estimateur moyen d'une cible $x_{k,j}$ à l'itération k devient :

$$\begin{aligned}
 \hat{x}_{k|k,j} &= \mathbb{E} [x_{k,j} | \mathbf{Z}^k] \\
 &= \sum_{i=1}^{m_{k,j}} \mathbb{P} \{ \theta_{k,i} | \mathbf{Z}^k \} \mathbb{E} [x_{k,j} | \theta_{k,i}, \mathbf{Z}^k] \\
 &= \sum_{i=1}^{m_{k,j}} \beta_{k,j}^{(i)} \hat{x}_{k|k,j}^{(i)}
 \end{aligned} \tag{1.109}$$

avec $\hat{x}_{k|k,j}^{(i)}$ l'état estimé partiel de la cible j avec la mesure $z_{k,j}$ et $\beta_{k,j}^{(i)}$ le poids accordé à l'association de la mesure i avec la cible j , tel que :

$$\sum_{i=0}^{m_{k,j}} \beta_{k,j}^{(i)} = 1 \tag{1.110}$$

Tous les détails concernant le calcul des état estimés partiels $\hat{x}_{k|k,j}^{(i)}$ et des poids $\beta_{k,j}^{(i)}$ peuvent être trouvés dans [Bar-Shalom 1995].

L'avantage essentiel du PDAF est sa facilité de mise en œuvre et sa faible charge en calculs (à peine supérieure à la charge d'un filtre de Kalman classique), sa prise en compte des fausses alarmes et de la détection non unitaire de la cible.

Ses inconvénients restent la nécessité d'avoir un module spécifique d'initialisation de piste, et une plage limitée de fonctionnement. Il a été montré qu'en général les performances du PDAF se dégradent vite lorsque le nombre moyen de mesures considérées est supérieur à 3 [Dezert].

Cas multicible : le JPDAF Le JPDAF est une extension du PDAF au cas multicible.

Le principe, si les cibles n'interfèrent pas entre elles, est exactement le même qu'avec le PDAF. Après une étape de fenêtrage statistique, chaque cible est associée à l'ensemble des mesures appartenant à sa fenêtre de validation. Cependant, pour les cibles qui interfèrent (qui ont au moins une mesure commune dans leur fenêtre de validation), l'ensemble des hypothèses d'association est considéré à partir des hypothèses de départ suivantes :

- Le nombre total N_k de cibles à pister est supposé connu.
- L'état initial de chaque piste est connu.
- Les modèles de dynamique des cibles peuvent être différents.
- Chaque cible ne génère qu'une mesure (pas de cibles étendues).
- Chaque mesure ne peut provenir que d'une seule cible (pas de cibles non-résolues).

Pour éviter des notations trop lourdes, nous considérons que l'ensemble des cibles ne constitue qu'un seul cluster, c'est à dire un ensemble de cibles qui ont des mesures communes dans leur fenêtre de validation. Dans le cas de plusieurs clusters, le processus est à reproduire pour chaque cluster.

Pour chaque cluster, l'ensemble des évènements d'associations possibles considérés est noté $\Theta_k = \{\Theta_k^a\}$ tel que Θ_k^a est un scénario a d'association possible. L'ensemble des évènements d'associations possibles est décrit par la matrice Ω_k défini comme telle :

$$\Omega_k \triangleq [\omega_{ji}] \quad i = 1, \dots, m_k \quad j = 0, \dots, N_k \tag{1.111}$$

Le coefficient j commence à 0, car il sert à considérer l'évènement « La mesure est une fausse alarme ».

À titre d'exemple dans le scénario décrit dans la Figure 1.22, la matrice de validation Ω_k s'écrit :

$$\Omega_k = \begin{bmatrix} 1 & 1 & 1 \\ 1 & 0 & 1 \\ 1 & 0 & 1 \end{bmatrix} \quad (1.112)$$

telle que $\omega_{ji} = 1$ signifie que l'association est possible entre la mesure $z_{k,j}$ et la cible $x_{k,i}$. Par ailleurs, l'évènement « la mesure j est associée à la cible $i = 0$ » signifie que la mesure j est une fausse alarme. Comme toutes les mesures peuvent être des fausses alarmes, les éléments de la première colonne sont égaux à 1.

À partir de cette matrice, chaque évènement d'association Θ_k^a peut être transcrit sous la forme d'une matrice $\hat{\Omega}_k^a$ telle que :

$$\hat{\Omega}_k^a \triangleq [\omega_{ji}(\Theta_k^a)] \quad i = 1, \dots, m_k \quad j = 0, \dots, N_k \quad (1.113)$$

Au vu des hypothèses énumérées précédemment (une cible ne peut être associée qu'à une mesure et une mesure ne peut provenir que d'une seule cible), sept matrices d'association possibles sont générées telles que :

$$\begin{aligned} \hat{\Omega}_k^1 &= \begin{pmatrix} 1 & 0 & 0 \\ 1 & 0 & 0 \\ 1 & 0 & 0 \end{pmatrix} & \hat{\Omega}_k^2 &= \begin{pmatrix} 1 & 0 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 1 \end{pmatrix} \\ \hat{\Omega}_k^3 &= \begin{pmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{pmatrix} & \hat{\Omega}_k^4 &= \begin{pmatrix} 0 & 1 & 0 \\ 1 & 0 & 0 \\ 0 & 0 & 1 \end{pmatrix} \\ \hat{\Omega}_k^5 &= \begin{pmatrix} 1 & 0 & 0 \\ 0 & 0 & 1 \\ 1 & 0 & 0 \end{pmatrix} & \hat{\Omega}_k^6 &= \begin{pmatrix} 0 & 1 & 0 \\ 1 & 0 & 0 \\ 1 & 0 & 0 \end{pmatrix} \\ \hat{\Omega}_k^7 &= \begin{pmatrix} 0 & 0 & 1 \\ 1 & 0 & 0 \\ 1 & 0 & 0 \end{pmatrix} \end{aligned}$$

Ainsi la matrice $\hat{\Omega}_k^1$ correspond à l'hypothèse, « Toutes les mesures sont des fausses alarmes ».

Finalement, l'estimateur moyen d'une cible se fait conformément à (1.109). Seule l'estimation du poids accordé à chaque association cible/mesure est modifiée telle que :

$$\beta_{k,j}^{(i)} = \sum_{\forall \Theta_k^a \subset \Theta_k} \mathbb{P} \{ \Theta_k^a | \mathbf{Z}^k \} \cdot \omega_{ji}(\Theta_k^a) \quad (1.114)$$

$$\beta_{k,j}^{(0)} = 1 - \sum_{i=1}^{m_k} \beta_{k,j}^{(i)} \quad (1.115)$$

de telle façon que chaque ensemble d'évènements d'association Θ_k^a soit pris en compte, par analogie au cas monocible où un seul ensemble d'évènements d'association $\theta_{k,j}$ est envisagé pour une cible j .

Ainsi le cœur du problème réside maintenant dans l'estimation de $\mathbb{P} \{ \Theta_k | \mathbf{Z}^k \}$. Le détail de ce calcul, qui n'est pas l'objet de ce manuscrit, est détaillé dans [Dezert].

Finalement, pour conclure sur le JPDAF, ses avantages sont les suivants : sa relative simplicité de mise en œuvre et ses bons résultats tant que le cluster n'est pas trop gros et que le nombre de fausses alarmes est relativement faible. Cependant, de nombreuses limitations sont à prendre en compte : le nombre N_k de cibles pistées doit être connu, les pistes doivent être initialisées, le nombre de matrices d'association croît exponentiellement avec le nombre de cibles dans un cluster.

A noter que différentes variantes de l'algorithme existent, notamment l'IPDAF [Musicki 1994] qui proposent une méthode d'initialisation des pistes.

1.4.7 Comparaison des différentes méthodes

Nous avons présenté trois approches pour le pistage multicible. Pour y voir plus clair, les avantages et inconvénients des différents algorithmes sont présentés dans le tableau 1.3.

	NN	MHT	JPDA	Part.	CPHD
Estimation de la position des cibles	😊	😊	😊	😊	😊
Estimation de la vitesse des cibles	😞	😊	😊	😊	😞
Robustesse aux manœuvres	😞	😊	😞	😊	😊
Estimation du nombre de cibles	😞	😊	😞	😞	😊
Initialisation de nouvelles pistes	😞	😊	😊	😞	😊
Fin des pistes	😞	😊	😞	😞	😊
Gestion des cibles proches	😞	😞	😊	😞	😊
Complexité algorithmique	😊	😊	😊	😞	😊
Robustesse aux fausses alarmes	😞	😊	😊	😞	😞
Robustesse aux non-détections	😞	😊	😞	😞	😞
Adaptable aux modèles non-linéaires	😊	😊	😞	😊	😊
Adaptable aux modèles non-gaussiens	😞	😞	😞	😊	😊

😊 Très adapté - 😊 Adapté mais peut être amélioré par l'utilisation d'autres techniques
 - 😞 Peu adapté, mais améliorable au prix de sacrifices combinatoires - 😞 Pas trop adapté - 😞 Pas du tout adapté

Tab. 1.3 – Avantages et inconvénients des techniques de pistage existantes
 NN : Nearest Neighbor - MHT : Multiple Hypothesis Tracker - JPDAF : Joint Probabilistic Data Association Filter - Part. : Filtre Particulaire - CPHD : Cardinalized Probability Hypothesis Density

Concernant la robustesse aux manœuvres des cibles, il est important de comprendre que celle-ci est un compromis entre un bruit de mesure faible et la précision de l'estimation. En effet, plus le bruit de mesure est grand, plus l'ellipse de covariance prédite est grande et l'algorithme est robuste aux manœuvres. Cependant, la contrepartie est que l'association mesures/cibles est plus délicate en cas de cibles proches ou en présence de fausses alarmes. Il faut également noter qu'un algorithme appelé IMM pour *Interacting Multiple Model* permet de pister avec plus de précision les cibles manœuvrantes [Blom 1988, Bar-Shalom 1993]. Tous les algorithmes que nous avons énumérés peuvent être hybridés avec un IMM. Le principe est de considérer plusieurs modèles de mouvement pour les cibles, d'estimer conjointement l'état des cibles en considérant ce modèle et de pondérer l'estimation globale par la probabilité que la cible suive effectivement ce modèle de mouvement. Cependant, considérer un trop grand nombre de modèles conduit à la dégénérescence du filtre, il est donc courant, lorsqu'on utilise cette technique de considérer seulement deux modèles. Le premier est un modèle CV (Constant Velocity) qui correspond à une trajectoire rectiligne avec vitesse constante, avec un faible bruit de modèle, pour pister avec finesse les cibles non manœuvrantes. Le second est également un modèle CV mais avec un bruit de modèle fort pour pister les cibles manœuvrantes.

A titre indicatif, il existe d'autres méthodes, notamment toutes les classes de méthodes dites *batch*, qui ne sont pas décrites ici car dans le cadre de notre application quasi-temps réel, ce type de méthode n'est pas adapté. En effet, il s'agit de méthodes à fenêtre glissante qui sélectionnent la meilleure association possible *a posteriori* de façon à estimer $\hat{x}_{k-s|k}$, ce qui induit un retard dans l'estimation. Une des méthodes de cette sorte très utilisée est celle du SD-assignment [Deb 1997]. Il existe aussi le PMHT développé par Streit [Streit 1995].

Le tableau 1.3 résume les avantages et inconvénients de chacune des approches présentées. Dans le cadre de notre application de suivi de cibles proches (convoi), il apparaît qu'aucune de ces approches n'est totalement satisfaisante. Par conséquent, on se propose dans le chapitre 2 d'hybrider deux des méthodes décrites afin de pallier leurs faiblesses.

1.5 Différentes approches pour représenter un système

La détection d'objets d'intérêt nécessite de modéliser des informations de haut niveau sémantique, c'est à dire riche de sens pour un opérationnel. Il s'agit souvent d'informations structurelles (temps, espace, causalité, ...) qu'il est nécessaire de modéliser sous la forme d'un système. Ainsi, les objets d'intérêt peuvent être considérés comme des systèmes évoluant au cours du temps (ou non-stationnaire). Un système est représenté par des états partiels, indépendants ou non, observés par des mesures au cours du temps. Afin d'organiser leur détection et l'estimation de leur état, on étudie dans cette partie les principales représentations symboliques d'un système. En effet, on cherche un formalisme pour représenter les connaissances que nous avons ainsi que les règles d'évolution du système étudié. Les objectifs de ces représentations sont multiples :

- Représenter la connaissance que nous avons du système étudié de la manière la plus précise possible.
- Développer une stratégie de raisonnement pour mettre en correspondance les observations avec le système.
- Créer des mécanismes de propagation de l'information.
- Garder des traces de l'évolution du système au cours du temps.

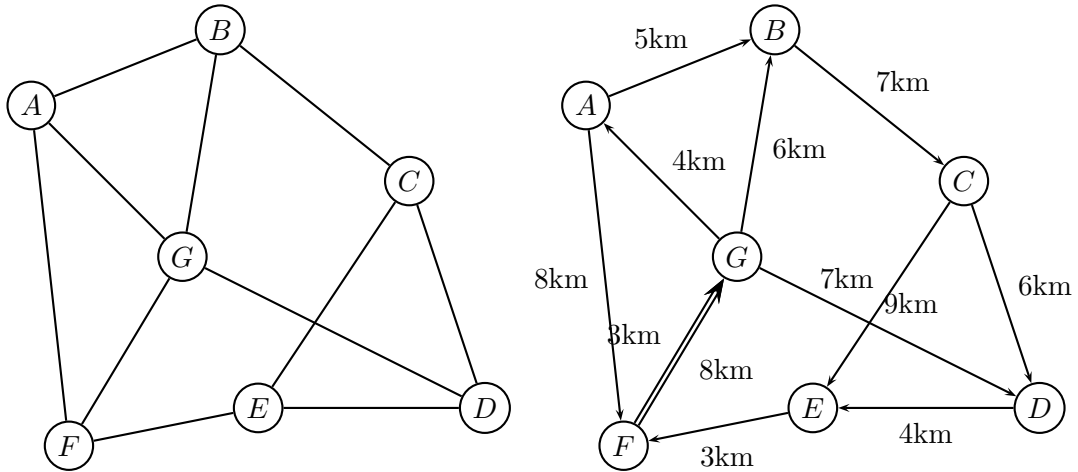


Fig. 1.30 – Un exemple de graphe non-orienté simple

Fig. 1.31 – Un exemple de graphe complexe

1.5.1 Les graphes

Un graphe est une représentation symbolique d'un réseau. Un graphe \mathcal{G} consiste en un ensemble de nœuds \mathcal{V} et d'arêtes \mathcal{E} . La modélisation du système peut être très simple (cf. Figure 1.30) ou beaucoup plus complexe (cf. Figure 1.31) avec orientation des arêtes ou encore notion de distance pour les arêtes.

Le principal avantage pour la représentation d'un système par un graphe est qu'il met en évidence les relations (de n'importe quel type) entre des objets. Par ailleurs, d'un point de vue combinatoire, un graphe peut être représenté de manière matricielle afin de faciliter les calculs. Cependant, il n'y a pas, dans un graphe de représentation des connaissances incertaines.

Selon sa structure, diverses applications sont possibles : recherche du plus court chemin, ordonnancement, reconnaissance de scène [Hongeng 2004], reconnaissance de visages [Wiskott 1997] et classification de scènes [Le Saux 2005].

1.5.2 Les automates

Les automates sont des objets mathématiques, très utilisés en informatique, qui permettent de modéliser un grand nombre de systèmes. Un automate modélise ainsi l'ensemble des états d'un système, reliés entre eux par des transitions qui sont représentées par des symboles. Étant donné un « mot » fourni en entrée, l'automate lit les symboles du mot un par un et va d'état en état selon les transitions. Le mot lu est soit accepté par l'automate soit rejeté.

Un automate est un quadruplet $A = (X, \Sigma, \phi, X_0)$ avec :

- X est un ensemble fini d'états ou modes
- Σ est un alphabet
- X_0 est l'ensemble des états initiaux de l'automate

– ϕ la fonction de transition de l'automate

En fonction des séquences reçues (issues de l'alphabet) et de l'état initial, l'automate est alors capable de définir dans quel état est le système à n'importe quel instant.

Il existe de nombreuses variantes pour les automates [Kauffman 1984], parmi lesquels on peut distinguer deux types principaux : les déterministes et les non-déterministes. Dans le premier cas, les transitions possibles sont uniques, on peut donc déterminer avec certitude dans quel état est l'automate. Dans le deuxième cas, il s'agit d'un automate tel que dans un état donné, il peut y avoir plusieurs transitions avec le même symbole. Le fonctionnement d'un tel automate n'est donc pas totalement « déterminé », car on ne sait pas quel état l'automate va être.




Fig. 1.32 – Un automate déterministe
- Reconnaissance de la chaîne 01

En bleu les états finaux - En rouge les états initiaux




Fig. 1.33 – Un automate non-déterministe
- Accepte tous les mots terminés par la chaîne 01

L'avantage est la grande clarté de représentation de cette méthode. L'inconvénient est qu'elle est adaptée pour un nombre limité d'états et qu'elle est efficace seulement lorsque l'on connaît parfaitement le système à modéliser. Cette représentation ne semble donc pas très bien adaptée de par la complexité de notre système à modéliser et de par nos méconnaissances.

Les applications des automates sont nombreuses : vérification d'un circuit électronique, recherche d'occurrence dans un texte (moteur de recherches sur le web [Henzinger 2004], etc.), étude du génome, classification d'images [Largouët 2000].

1.5.3 Les gabarits

Dans ses travaux, Virginie Eude [Eude 1998] a utilisé le formalisme des gabarits avec des contraintes temporelles et spatiales floues pour faire de la reconnaissance d'activités militaires. Cette technique est efficace pour reconnaître des activités définies très précisément.

Les gabarits servent à décrire les différentes étapes de la réalisation d'une activité particulière. Ces étapes sont elles-mêmes décomposées en étapes de plus bas niveau et ainsi de suite jusqu'à atteindre des activités élémentaires identifiables directement par des observations. Ainsi, les gabarits ont des structures d'arbres, dont la racine représente l'instance globale à reconnaître, les feuilles sont des observations et les nœuds des événements intermédiaires reconnaissables. Les feuilles et les nœuds sont liés par des relations d'agrégation. Le mot agrégation désigne l'action de regrouper des éléments grâce à des opérateurs tels que la conjonction ou la disjonction.

De plus, comme chaque sous-événement peut être plus ou moins significatif pour la reconnaissance de l'évènement de niveau supérieur, à chaque branche est associé un

degré d'importance. On peut ainsi finalement évaluer la certitude de la reconnaissance de chaque sous activité ainsi que celle de l'activité racine. La figure 1.34 illustre ce concept.




Fig. 1.34 – Un exemple de gabarit - *Entraînement sur site*

Le gabarit présenté sur la figure 1.34 modélise un entraînement sur site. Les informations sont des mesures météorologiques et issues de capteurs altimétriques, ainsi que des informations humaines indiquant s'il y a un entraînement base ou ops. L'agrégation **ET** indique qu'une activité *Entraînement sur site* est reconnue lorsque les trois événements *2 entraînements*, *Reconnaissance Météo* et *reconnaissance radar altimétrique* sont reconnues. De même, l'activité *2 entraînements* est l'agrégation des activités *Entraînement ops* et *Entraînement base*, mais cette fois la relation d'agrégation les liant est représentée par un **OU+**. Cette agrégation est plus forte qu'un **OU** logique classique, c'est à dire que la reconnaissance d'une des deux activités suffit pour la reconnaissance de l'activité *2 entraînements*, mais la reconnaissance des deux activités renforce la certitude de l'activité *2 entraînements*.

1.5.4 Les réseaux bayésiens

Un réseau bayésien sert à représenter la connaissance que l'on a d'un système. Il se présente sous la forme d'un graphe acyclique dans lequel chaque nœud représente une variable et les arcs symbolisent l'influence d'une variable sur une autre. À chaque arc est également associé une distribution de probabilité conditionnelle. Le processus d'inférence qui permet de déterminer la probabilité d'un évènement sous certaines conditions est basé sur la formule de Bayes.

Les relations de dépendances permettent de limiter la combinatoire pour le calcul de l'état d'un système $X = \{X_1, \dots, X_N\}$ grâce à la relation suivante :

$$P \{x_1, \dots, x_n\} = \sum_{i=1}^N P \{(x_i | Pa(x_i))\} \tag{1.116}$$

où $Pa(x_i)$ représente les nœuds parents de x_i .

Le réseau bayésien est très utilisé pour calculer l'évolution des distributions de probabilité d'un ensemble de variables aléatoires. En fonction des informations observées, la probabilité des données non observées est calculée. Par exemple, en fonction des symptômes d'un malade, il est possible de calculer les probabilités des différentes pathologies compatibles avec ces symptômes. On peut aussi calculer la probabilité de symptômes non observés, et en déduire les examens complémentaires les plus intéressants. Un tutoriel très complet sur le domaine est proposé par Heckerman [Heckerman 1995].




Fig. 1.35 – Un exemple de réseau bayésien

Les applications liées aux réseaux bayésiens sont très nombreuses. Elles concernent souvent des activités liées aux problèmes de diagnostic (*cf.* Figure 1.35) et détection de panne. Nous pouvons citer par exemple une application d'évaluation du taux de menace d'une zone donnée du aux attaques aériennes [Okello 2003], la détection de scènes violentes pour la vidéo-surveillance dans le métro [Kumar 2005] ou encore l'aide au diagnostic [Djebbar 2006].

Il existe de nombreuses variantes des réseaux bayésiens. Il est alors possible d'intégrer une composante temporelle. Ainsi, les réseaux bayésiens dynamiques permettent de représenter l'évolution des variables d'un systèmes en représentant l'influence entre leurs valeurs à l'itération $k - 1$ et leurs valeurs à l'itération k .

La grande force des réseaux bayésiens est de tenir compte simultanément de connaissances *a priori* d'experts (dans le graphe) et de l'expérience contenue dans les données. L'inconvénient majeur est celui de l'initialisation des probabilités initiales.

Une description approfondie des réseaux bayésiens est disponible en Annexe A.

1.5.5 Les modèles de Markov cachés

Un modèle de Markov caché (MMC) – en anglais Hidden Markov Models (HMM) (ou plus correctement, mais moins employé automate de Markov à états cachés) est un modèle statistique dans lequel le système modélisé est supposé être un processus Markovien de paramètres inconnus [Rabiner 1989]. Il a été proposé pour la première fois à la fin des années 60. Il représente un objet donné par deux suites de variables aléatoires : l'une dite cachée et l'autre observable (*cf.* Figure 1.36). Les variables cachées représentent les états x possibles du système de taille n_x , tandis que les variables observables sont les observations de taille n_z .

Mathématiquement, un HMM est défini par le triplet (x_0, A, B) où x_0 est l'état initial du système, A est la matrice de transition markovienne de taille $n_x \times n_x$ d'un état à l'itération k vers un état à l'itération $k + 1$ et B est la matrice de passage de l'espace d'état vers l'espace d'observation de taille $n_x \times n_z$.

La figure 1.36 illustre le concept des HMM pour le filtrage de Kalman où l'état d'une cible x_k est la variable cachée et z_k est la variable observable. La matrice A correspond au modèle de transition de l'état F_k (*cf.* (1.55)) et la matrice B correspond à H (*cf.* (1.56)).

Les HMM sont adaptés pour trois types de problèmes :

- connaissant l'automate, calculer la probabilité d'une séquence particulière (se résout à l'aide de l'algorithme de Viterbi),




Fig. 1.36 – La problématique du filtrage de Kalman vue sous la forme d’un HMM - en rouge les variables observables - en bleu, les variables cachées

- connaissant l’automate, trouver la séquence la plus probable d’états (cachés) ayant conduit à la génération d’une séquence de sorties donnée (se résout également avec l’algorithme de Viterbi),
- étant donné une séquence de sortie, retrouver l’ensemble d’états le plus probable et les probabilités des sorties sur chaque état. Se résout avec l’algorithme de Baum-Welch, appelé aussi algorithme forward-backward.

L’avantage des HMM est sa bonne gestion des données manquantes, ainsi que sa possibilité de factorisation et de hiérarchisation du problème. Les inconvénients majeurs sont sa complexité algorithmique compensée par des algorithmes tout de même coûteux en temps, ainsi que l’effet boîte noire qui entraîne un manque de transparence pour une interaction avec un opérationnel.

En règle générale, les applications se situent dans le domaine de la reconnaissance du génome [Krogh 2001], reconnaissance de séquences vidéos [Ramasso 2007b], du traitement automatique du langage naturel [Boulard 2003], mais également pour la détection de menaces [Singh 2004] ou encore le pistage vidéo [Lan 2004].

1.5.6 Les réseaux de neurones

Les réseaux de neurones (ou Artificial Neural Network en anglais) sont principalement utilisés pour la modélisation et la classification de systèmes dont la dynamique est non-linéaire. Leur utilisation est adaptée pour des situations où le modèle est trop complexe et l’expertise du procédé est difficile à formuler mais où de grandes quantités de données et de situations sont disponibles. Ces données sont alors utilisées pour développer un modèle de boîte noire capable de reproduire le comportement du système. Un réseau de neurones est un ensemble de processus élémentaires interconnectés qui, à l’image de neurones connectés dans le cerveau par des synapses, traitent dynamiquement les informations reçues. L’apprentissage du réseau de neurones détermine le poids de chaque connexion entre les neurones permettant de minimiser l’erreur de prédiction du modèle non-linéaire.

Il existe de nombreuses applications, notamment en biologie [Simani 2000, Venkatasubramanian 1990]. Dans [Adeli 2001], Adeli propose un état de l’art très complet des travaux effectués avec les réseaux de neurones entre 1989 et 2000. Leur efficacité a été prouvée lorsque la quantité de données pour l’apprentissage est suffisante. Cependant, l’effet boîte noire empêche de suivre l’évolution du système au cours du temps.

1.5.7 Les réseaux de Petri

Un réseau de Petri est un outil graphique de modélisation et d'analyse des systèmes parfaitement adapté à l'étude des structures de contrôle [Peterson 1981]. Il permet notamment de maîtriser et d'assurer la sûreté de fonctionnement de logiciels complexes (aéronautique, transports, industrie...).

Un réseau de Petri est défini comme un 6-uplet $\langle P, T, F, M_0, Pre, Pos \rangle$, où

- P est un ensemble de places tel que $P = p_1, p_2, \dots, p_m$
- T est un ensemble de transitions tel que $T = t_1, t_2, \dots, t_l$
- F est un ensemble d'arcs tel que $F = a_1, a_2, \dots, a_n$
- M_0 est le marquage initial représentant à l'instant initial le nombre de jetons contenu dans chaque place.
- $Pre : PxT \rightarrow N$ est l'application *place précédente*
- $Pos : PxT \rightarrow N$ est l'application *places suivantes*

La figure 1.37 illustre ce concept.




Fig. 1.37 – Un exemple de réseaux de Petri

Les points forts d'un réseau de Petri sont ses facilités de séquençage, de synchronisation et de parallélisme. De nombreuses versions sont par ailleurs disponibles en fonction du type d'application souhaitée : les réseaux de Petri continus, les réseaux de Petri colorés [Jensen 1996]...

Le point faible de cette représentation est principalement qu'il faut connaître parfaitement le système à modéliser.

Il existe donc de nombreuses applications dans le cadre de la surveillance, de la gestion de ressource ou encore la synchronisation de machines. Nous pouvons citer particulièrement les réseaux de Petri hybrides de Charles Lesire [Lesire 2006] qui combinent une modélisation de systèmes par les réseaux de Petri avec un filtrage particulière pour estimer les états discrets du système.

1.5.8 Les chroniques

Un modèle de chronique est destiné à représenter un schéma d'évolution d'une partie du monde [Dousson 1994]. Il est composé d'instant, d'évènements, d'assertion, de contraintes temporelles entre les différents instants et d'actions à exécuter lorsque le système peut conclure que l'environnement a bien suivi l'évolution décrite par cette

chronique (*i.e.* la reconnaissance a eu lieu) ou bien qu'une reconnaissance est envisageable d'ici un certain délai fixé par l'utilisateur.

L'avantage par rapport à d'autres méthodes comme les automates est l'insertion des contraintes temporelles. Cependant comme pour les méthodes précédemment citées, il faut connaître parfaitement le système à reconnaître. De plus, cette méthode ne prend pas en compte les événements cachés.

Rota [N.A. Rota 2000] a grâce à cette méthode fait de la reconnaissance d'activités sur des images vidéos. Choppy utilise les chroniques pour la simulation de systèmes complexes [Choppy 2009].

1.5.9 Comparaison des différentes méthodes

Dans cette partie, nous avons décrit quelques unes des techniques envisageables pour la détection d'évènements et/ou d'objets. Ces techniques sont souvent utilisées pour la détection d'évènements sur vidéo et l'étude bibliographique [Leignel 2008] fait référence à des techniques similaires.

	<i>Graphe</i>	<i>Automate</i>	<i>Gabarit</i>	<i>Réseau bayésien</i>	<i>HMM</i>	<i>Réseau de neurones</i>	<i>Réseau de Petri</i>	<i>Chronique</i>
v.a. discrète	oui	oui	oui	oui	oui	oui	oui	oui
v.a. continue	non	non	non	oui	oui	oui	non	non
Évolution temporelle	non	non	non	oui	oui	oui	non	non
Cadre de disc. ≠	oui	non	oui	oui	oui	non	non	non
Dépendances entre les v.a.	oui	oui	oui	oui	oui	non	oui	non
Données manquantes	non	non	oui	oui	oui	oui	non	non
Données asynchrones	oui	oui	oui	oui	oui	non	non	non
Apprentissage	non	non	non	oui	oui	oui	non	non
Importante quantité de données	oui	0	oui	oui	oui	oui++	oui	oui
Combinatoire	oui	oui	oui	oui	oui	non	oui	oui
Rec. séquentielle	non	oui	non	non	oui	non	oui	oui

Tab. 1.4 – Avantages et inconvénients des représentations symboliques d'informations

Conclusion

La détection d'objets d'intérêt ne constitue pas une tâche triviale. Il faut dans un premier temps définir ce qu'est un objet d'intérêt et quels sont les moyens (capteurs, information *a priori*, etc.) dont nous disposons pour atteindre notre objectif. L'étude de ces moyens nous permet de sélectionner les techniques auxquelles nous nous intéressons à partir de la troisième partie. Par la suite, nous nous sommes donc intéressés aux techniques de trajectographie multicible existantes, aux différents modes de représentation de l'information ainsi qu'aux représentations symboliques pour un système non-stationnaire.

L'analyse bibliographique des techniques de pistage multicible existantes a montré qu'elles n'étaient pas satisfaisantes pour la détection d'objets d'intérêt comme un convoi de véhicules. C'est pourquoi, nous proposons, dans la première partie de ce manuscrit, une nouvelle technique de pistage pour résoudre notamment le problème du pistage de cibles proches.

Concernant la partie détection d'objets d'intérêt (Partie II), nous avons décidé de nous focaliser sur l'objet d'intérêt convoi dans le but de généraliser la méthode à n'importe quel type d'objets d'intérêt. Parmi les techniques de représentation des systèmes, nous avons sélectionné les réseaux bayésiens, car ils permettent une représentation intuitive du système et ils prennent en compte facilement l'hétérogénéité des données ainsi que les aspects temporels. Il s'agit donc d'un premier cadre de représentation des données probabiliste. Nous nous sommes intéressés par la suite à une représentation par les réseaux crédibilistes, car la représentation par les masses de croyances permet une analyse plus fine du problème, grâce à la modélisation du conflit et du doute.

I

Pistage multicible adapté au pistage de cibles proches

Hybridation des algorithmes PHD et MHT

Sommaire

2.1	Comparaison des algorithmes de pistage multicible existants . . .	70
2.2	Création d'un algorithme hybride CPHD et MHT	73
2.2.1	Hybridation du filtre CPHD et du MHT	73
2.3	Implémentation du filtre CPHD par mélange de gaussiennes . . .	76
2.3.1	Le théorème des sommes gaussiennes	76
2.3.2	Les hypothèses de modèles gaussiens	76
2.3.3	Le filtre GM-CPHD	77
2.3.4	Équations de prédiction	77
2.3.5	Équations de mise à jour	78
2.3.6	Implémentation	79
2.3.7	L'évaluation du nombre de cibles	80
2.4	Labellisation du filtre CPHD	81
2.4.1	Problématique	81
2.4.2	Approches existantes pour la labellisation	82
2.4.3	Matrice d'association	83
2.4.4	Poids global d'une association	86
2.4.5	La matrice de coût	87
2.5	Optimisation de l'algorithme de labellisation	88

Introduction

Dans la partie 1.4, l'état de l'art a montré que de nombreux algorithmes de pistage multicible existent, avec des approches très différentes, mais avec ce point commun qu'est l'inférence bayésienne. Nous avons présenté leurs avantages ainsi que leurs inconvénients par rapport aux problématiques liées au pistage multicible, comme le traitement des cibles proches, la gestion des fausses alarmes ou encore la robustesse aux manœuvres. L'objectif de ce chapitre est maintenant de créer un algorithme de pistage multicible le plus performant possible au vu des caractéristiques GMTI et dans le cadre de la détection d'objets d'intérêt.

Dans la première partie 2.1, nous comparons les algorithmes existants dans le cadre de la problématique GMTI. Aucun algorithme ne satisfait toutes les contraintes GMTI. Une idée est donc d'hybrider ou de combiner deux méthodes afin de conserver uniquement leurs avantages ou encore de limiter leurs faiblesses. C'est pourquoi, dans la partie 2.2, nous

décrivons l'hybridation des deux algorithmes CPHD et MHT qui peuvent être vus comme complémentaires pour notre problématique. Cependant, dans ce cadre, l'utilisation de ces algorithmes dans une hybridation nécessite des adaptations. Comme les implémentations du filtre CPHD sont très récentes et complexes, nous décrivons une implémentation par mélange de gaussiennes du filtre CPHD (Partie 2.3). Par ailleurs, dans la version classique décrite, le filtre CPHD¹ ne possède pas de techniques de labellisation des pistes; nous en proposons donc une qui est décrite dans la partie 2.4. Pour finir, la longueur des temps de calcul pour cette partie nous a conduits à proposer une version optimisée de l'algorithme qui est décrite dans la partie 2.5.

2.1 Comparaison des algorithmes de pistage multicible existants

Dans le cadre d'une évaluation complète et dynamique de la situation, trois points sont cruciaux : la détection des objets (donc la capacité à initialiser et terminer des pistes), la précision de l'estimation de l'état des cibles détectées quelles que soient les conditions (cibles proches ou éloignées les unes des autres) et la capacité à pister un nombre important d'objets. La précision dans l'estimation de l'état est recherchée aussi bien en position qu'en vitesse. En effet, dans le cadre de la détection de convois, le positionnement spatial est aussi discriminant que la vitesse pour déterminer si un agrégat de véhicules est un convoi ou non.

Rappelons brièvement les contraintes d'observation des cibles par un capteur GMTI :

- Volume d'observation V_k très grand, ce qui entraîne une zone d'observation de plusieurs km^2
- Quantité très importante de données à traiter notées m_k (d'une dizaine à plusieurs centaines de plots à traiter)
- Probabilité de détection non-unitaire : $P_d < 1$
- Densité de fausses alarmes importante : $\beta_{fa} > 0$
- Période d'échantillonnage très longue : $3 \leq \Delta \leq 10$ s

Par ailleurs les difficultés de pistage proviennent aussi du comportement des cibles :

- Importante quantité de cibles
- Cibles fortement manœuvrantes
- Cibles proches qui génèrent des cibles non-résolues et des ambiguïtés au niveau de l'association cibles/mesures

La figure 2.1 illustre les difficultés liées à notre problématique en présentant les ensembles de plots MTI à deux itérations successives. On observe ici qu'il est difficile d'associer les plots d'une itération à l'autre à cause de la proximité des cibles, des fausses alarmes et des cibles non-détectées.

L'ensemble de ces problématiques de pistage a été largement abordé dans la littérature depuis de nombreuses années. Cependant, la difficulté à pister des cibles proches spatialement reste un point crucial, relativement peu traité. Waxman dans [Waxman 2004] propose une synthèse relativement complète sur le sujet. Notons qu'il est important

¹Cardinalized Probability Hypothesis Density

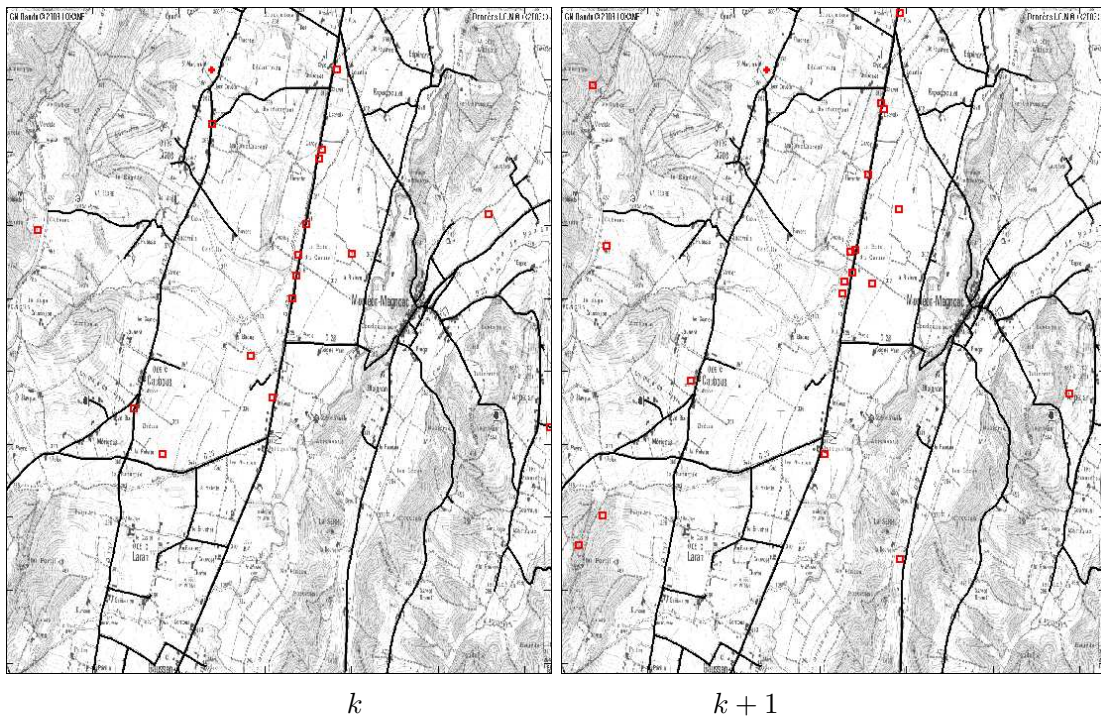


Fig. 2.1 – Ensemble des plots MTI à deux itérations successives - plots représentés par des carrés rouges

de bien distinguer deux cas de figures : dans le premier, on parle de pistage de cibles proches (appelées aussi *cluster*); dans le deuxième cas, on parle de pistage de convoi, l'hypothèse de départ étant que le convoi est détecté. Un algorithme spécifique de pistage de convois est alors réalisé [Salmond 1999, Gordon 1996]. Dans des travaux antérieurs, nous avons réalisé un algorithme spécifique de pistage de convois au milieu du trafic civil [Pollard 2008a] basé sur l'hypothèse de détection du convoi et sur le fait que le nombre de cibles le constituant est connu. Ce deuxième cas sort de notre cadre d'étude puisque nous nous intéressons à la détection de convois.

L'étude de la littérature a montré que lorsque des cibles sont proches, les performances de pistage (erreur d'estimation de l'état, complétude de pistage, pureté des pistes, ...) diminuent. Cela peut être attribué à deux facteurs. Tout d'abord, plus les cibles sont proches, plus leur résolution est faible (*i.e.* deux cibles non résolues ne génèrent qu'une seule mesure); par conséquent il est plus difficile d'estimer leur nombre. De plus, de par les mesures manquantes et la proximité des cibles, le problème d'association de mesures aux cibles est beaucoup plus complexe.

En étudiant le tableau comparatif 1.3, nous avons constaté que tous les algorithmes montrent des baisses de performance lorsque les cibles sont proches. Le filtre CPHD est un filtre bayésien récursif capable d'estimer conjointement l'état de plusieurs cibles ainsi que le nombre de cibles présent sur la zone d'observation en présence de bruit. Son excellente estimation du nombre de cibles sur une zone d'observation, lui permet de conserver des performances équivalentes avec des cibles distantes ou avec des cibles proches. Nous nous sommes donc intéressés en priorité à ce filtre. Néanmoins, il a été montré que ce filtre

peut montrer des déficiences notamment en présence de non-détections et lorsque la densité de fausses alarmes est mal évaluée [Erdinc 2005]. Des pistes restent à explorer [Erdinc 2009, Franken 2009]. Par ailleurs, le filtre CPHD seul ne constitue pas un candidat idéal pour notre problématique car il souffre de déficiences au niveau de l'estimation de la vitesse des cibles (critère très important pour le convoi). Il faut donc trouver un moyen de le combiner avec une autre technique de pistage afin de diminuer l'erreur sur l'estimation de la vitesse des cibles.

L'approche NN (Nearest Neighbour) a la plus faible complexité algorithmique. Cependant, elle ne propose pas de solutions pour diverses problématiques MTI : initialisation et fin de pistes, traitement des fausses alarmes et non détections, ... Par conséquent cette approche ne semble pas la plus appropriée dans le cadre de la détection d'objets d'intérêt. Elle est trop rudimentaire.

Le filtre JPDAF a de nombreux avantages, notamment sa robustesse aux fausses alarmes. De plus, il propose un traitement spécifique des agrégats de cibles en considérant toutes les combinaisons d'associations cibles/mesures. Cependant, deux facteurs le rendent non adapté à notre problématique. Premièrement, il faut être capable d'estimer le nombre de cibles dans l'agrégat avec précision et deuxièmement, au-delà de 8 cibles le problème devient impossible à traiter car le nombre de combinaisons d'association est trop important.

Le principal avantage du filtrage particulaire est son adaptabilité aux cas non-linéaires et/ou non-gaussiens, ce qui ne nous concerne pas puisque nous nous plaçons dans le cas linéaire gaussien (*cf.* (1.55) et(1.56)). Par ailleurs, le désavantage du filtrage particulaire est de devoir générer un nombre d'échantillons (particules) proportionnel au nombre de cibles, ce qui le rend inadapté pour pister un grand nombre de cibles.

Finalement, le MHT satisfait deux des points critiques de notre problématique : il combine un processus d'initialisation et de fin de piste efficace avec une précision de l'estimation de l'état des cibles satisfaisante. Son désavantage provient des baisses de performances, que l'on observe lorsque les cibles sont proches, dû à son incapacité à estimer le nombre de cibles présentes dans un agrégat.

Après analyse des différents algorithmes dans le cadre de notre problématique, il apparaît qu'aucune méthode n'est parfaitement adaptée. Cependant, il faut remarquer que le filtre CPHD est le seul dont les performances ne se dégradent pas lorsque les cibles sont proches. De plus, parmi les autres approches, il ressort que le MHT est le plus adapté à notre problématique de par la précision de son estimation et ce, malgré les baisses de performance que l'on observe lorsque les cibles sont proches. Finalement, nous pouvons voir ces deux algorithmes comme deux algorithmes complémentaires et notre objectif est de trouver un moyen de les combiner de façon à prendre les avantages du filtre CPHD et du MHT sans leurs inconvénients, comme cela est illustré par le tableau 2.1, dans lequel, les performances de l'algorithme hybride sont celles que nous souhaitons obtenir : à savoir tous les points forts du CPHD et du MHT sans leurs inconvénients. Les performances affichées dans le tableau correspondent donc à un « OU » logique, à l'exception du critère combinatoire car nous ne pouvons pas espérer que le temps de calcul soit égal au temps de

calcul minimal entre les deux algorithmes. Sur cette base, nous proposons une hybridation des deux algorithmes.

	PHD	MHT	Hybride
Estimation de la position des cibles			
Estimation de la vitesse des cibles			
Robustesse aux manœuvres			
Estimation du nombre de cibles			
Initialisation de nouvelles pistes			
Fin des pistes			
Gestion des cibles proches			
Complexité algorithmique			
Robustesse aux fausses alarmes			
Robustesse aux non-détections			

Très adapté - Adapté mais peut être amélioré par l'utilisation d'autres techniques - Peu adapté, mais améliorable au prix de sacrifices combinatoires - Pas trop adapté - Pas du tout adapté

Tab. 2.1 – Hybridation du filtre CPHD et du MHT

2.2 Création d'un algorithme hybride CPHD et MHT

Nous avons identifié deux algorithmes qui, s'ils sont combinés judicieusement, répondent à la problématique de pistage de cibles proches et de cibles éloignés. Dans cette partie, nous présentons comment les combiner judicieusement. Nous avons ainsi identifié deux enjeux :

- **Comment combiner ces algorithmes judicieusement, pour ne conserver que leurs avantages, sans leurs inconvénients ?**
- **Différentes formes implémentables des algorithmes sont possibles, lesquelles choisir ?**

2.2.1 Hybridation du filtre CPHD et du MHT

L'algorithme hybride proposé est décrit dans la figure 2.2. À partir de l'ensemble des mesures GMTI Z_k , on souhaite, à chaque itération k , obtenir, à la sortie de l'algorithme hybride, un ensemble de pistes \mathcal{T}_k décrivant aussi précisément que possible la dynamique des cibles X_k .

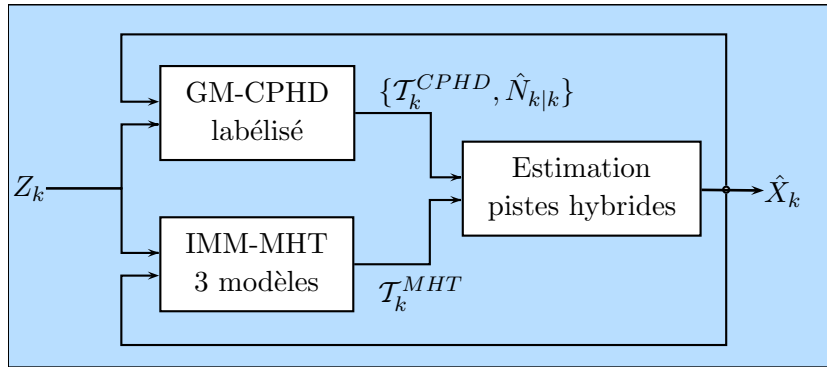


Fig. 2.2 – Hybridation IMM-MHT / GM-CPHD

L'idée est que chaque filtre traite indépendamment l'un de l'autre l'ensemble des mesures Z_k afin de fournir une estimation de l'état des cibles et/ou de leur nombre la plus précise possible. Le GM-CPHD fournit donc à chaque itération k un ensemble de pistes noté \mathcal{T}_k^{CPHD} et une estimation du nombre de cibles notées $\hat{N}_{k|k}$, tandis que le MHT fournit un ensemble de pistes noté \mathcal{T}_k^{MHT} confirmées ou non (cf. Partie 1.4.6.3). Finalement, lors de l'étape d'estimation hybride, on combine les pistes \mathcal{T}_k^{CPHD} et \mathcal{T}_k^{MHT} issues des deux algorithmes afin d'obtenir l'ensemble d'états estimés \hat{X}_k le plus proche de la réalité possible.

Nous décrivons à présent plus précisément les 3 blocs du synoptique l'algorithme hybride de la figure 2.2.

2.2.1.1 Le filtre CPHD

Le filtre CPHD est implémentable sous deux formes. Une modélisation particulière a été initialement proposée par Vo [Vo 2003, Vo 2005], mais elle comporte les mêmes désavantages que pour le filtrage particulaire, à savoir qu'il n'est pas envisageable de traiter un grand nombre de cibles. La deuxième possibilité est de modéliser la densité de probabilité jointe de l'ensemble des cibles sous la forme d'un mélange de gaussiennes (GM-CPHD) [Vo 2006c, Vo 2007]. Comme cette implémentation est relativement récente, nous la décrivons dans la partie 2.3.

Cette deuxième modélisation ne limite pas le nombre de cibles à pister et c'est donc celle-ci que nous adaptons pour toute la suite du manuscrit. Il est également possible de combiner l'approche PHD avec une approche multi-modèle (IMM) concernant la modélisation de la trajectoire des cibles [Punithakumar 2008, Pasha 2006, Pasha 2009] pour augmenter la robustesse aux manœuvres. La première référence concerne l'hybridation du SMC-PHD avec l'IMM et les deux suivantes concernent l'hybridation du GM-PHD avec l'IMM. A ce jour, aucune publication ne propose d'hybrider le GM-CPHD (que nous allons utiliser) avec l'IMM. Cependant, nous n'avons pas souhaité orienter nos travaux dans cette direction car si l'intégration d'un IMM avec le GM-CPHD améliore probablement l'estimation de la position des cibles, cela ne changera pas le fait que le GM-CPHD n'est pas adapté pour estimer correctement leur vitesse.

Par ailleurs, dans sa version classique, le filtre GM-CPHD ne considère pas le problème

de labellisation des pistes. Or, dans le cadre de notre application de surveillance, il est nécessaire de savoir identifier les cibles et il faut donc proposer une version labellisée du GM-CPHD. C'est l'une de nos contributions, elle est décrite dans la partie 2.4.

2.2.1.2 L'algorithme MHT

Concernant le MHT, nous utilisons l'approche orientée piste (TOMHT). L'intégration d'un IMM est peu coûteuse et permet d'améliorer notablement la précision de l'estimation de l'état des cibles et de rendre l'algorithme plus robuste aux manœuvres des cibles. C'est donc un IMM-MHT que nous allons utiliser. Concernant le choix des modèles le composant, nous nous référons aux travaux de Kirubarajan sur le sujet [Kirubarajan 2000a, Kirubarajan 2000b] qui, dans le cadre du pistage MTI, propose d'utiliser un IMM à trois modèles. Un modèle CV (Constant Velocity) à bruit de mesure faible pour pister les cibles ayant une trajectoire rectiligne et une vitesse uniforme, un autre modèle CV à bruit de mesure fort pour pister les cibles manœuvrantes et un modèle STOP, pour les cibles qui s'arrêtent.

Par ailleurs, la vraisemblance des pistes MHT s'obtient à partir du score de ces dernières. D'après Blackman [Blackman 1999], le score d'une piste l se calcule récursivement à partir du logarithme népérien du ratio de vraisemblance de la mesure z associée à la piste à l'itération k et du score de la piste à l'itération $k - 1$:

$$s_{k,l} = s_{k-1,l} + \ln \left(\frac{P_d}{\beta_{fa} + \beta_{nt}} \cdot g(z|\mathcal{T}_{k,l}) \right) \quad (2.1)$$

avec z la mesure associée à la piste, $g(z|\mathcal{T}_{k,l})$ la vraisemblance de la mesure associée à la piste l et β_{nt} la densité de probabilité de cibles naissantes.

Si la piste n'est associée à aucune mesure, alors :

$$s_{k,l} = s_{k-1,l} + \ln(1 - P_d) \quad (2.2)$$

Concernant l'initialisation,

$$s_{0,l} = \ln \left(P_d \cdot \frac{\beta_{nt}}{\beta_{fa}} \right) \quad (2.3)$$

2.2.1.3 L'estimation hybride

On souhaite, lors de l'estimation hybride, obtenir en sortie un ensemble \hat{X}_k d'états estimés qui soit le plus précis possible en terme de précision de l'état des cibles, mais également en terme de cardinalité. Par conséquent, on souhaite également être le plus réactif possible quant aux processus d'initialisation et de fin de pistes. Or, le filtre GM-CPHD fournit une très bonne estimation du nombre de cibles $\hat{N}_{k|k}$ et détecte très rapidement les débuts et fin de pistes, mais l'estimation de l'état des cibles est moins précise qu'avec l'IMM-MHT, spécialement pour la vitesse. Finalement, nous considérons le filtre GM-CPHD comme un premier filtre pour détecter les cibles et l'IMM-MHT comme un deuxième filtre pour préciser l'estimation de l'état. Ainsi, à partir des positions des pistes issues du GM-CPHD, les pistes hybrides sont choisies parmi les pistes MHT ayant le score le plus fort (*cf.* Partie 1.4.6.3) et statistiquement proches des pistes CPHD.

Concrètement, à chaque itération, on réalise un fenêtrage statistique autour de la position des pistes \mathcal{T}_k^{CPHD} pour sélectionner les pistes issues de \mathcal{T}_k^{MHT} , qui leur sont associables. Pour chaque piste CPHD, si plusieurs pistes MHT appartiennent à la fenêtre de validation, alors on sélectionne la piste MHT ayant le score le plus fort (donc la plus probable).

Si des pistes CPHD sont interférentes (elles ont des pistes MHT communes dans leur fenêtre de validation), alors on sélectionne la combinaison de pistes MHT dont la somme des scores est maximale (une piste MHT est associée à au plus une piste CPHD).

Si une piste CPHD ne contient aucune piste MHT dans sa fenêtre de validation, alors on conserve l'état estimé du filtre CPHD.

L'ensemble des états estimés finaux \hat{X}_k sont réinjectés dans les algorithmes CPHD et MHT. L'état estimé des cibles issue du filtre CPHD est mis à jour avec les états estimés améliorés par le MHT. Par ailleurs, si une piste issue du CPHD n'était associée à aucune piste du MHT, alors cette piste est intégrée dans l'arbre d'hypothèses du MHT.

Nous décrivons à présent l'implémentation du filtre CPHD par par mélange de gaussiennes ainsi que le processus de labellisation des piste pour le filtre GM-CPHD.

2.3 Implémentation du filtre CPHD par mélange de gaussiennes

Dans la partie 1.4.4, nous avons décrit les équations du filtre CPHD qui estime conjointement la fonction d'intensité v de la densité de probabilité jointe de l'ensemble des cibles X_k ainsi que sa cardinalité. Cependant, telles quelles, les équations ne sont pas implémentables. Il faut choisir une modélisation pour la fonction d'intensité v . Nous présentons à présent l'implémentation du filtre CPHD par mélange de gaussiennes.

La modélisation par mélange de gaussiennes est basée sur le théorème des sommes gaussiennes décrit dans la partie 2.3.1.

2.3.1 Le théorème des sommes gaussiennes

Le théorème des sommes de gaussiennes issu du théorème de Wiener énonce que toute densité v_k sur \mathbb{R}^d à l'itération k peut être approximée aussi précisément que voulu par une combinaison linéaire de densités gaussiennes :

$$v_k(x) = \lim_{n \rightarrow \infty} \sum_{i=1}^n w_{k,i} \cdot \mathcal{N}(x, m_{k,i}, P_{k,i}) \quad (2.4)$$

où l'expression $w_{k,i} \cdot \mathcal{N}(x, m_{k,i}, P_{k,i})$ représente une densité gaussienne d'intensité $w_{k,i}$, positionnée en x , de moyenne $m_{k,i}$ et de covariance $P_{k,i}$.

Il existe un nombre $N \in \mathbb{N}^*$, tel que $\forall \varepsilon > 0$,

$$\forall n > N, \quad \int |v_k(x) - \sum_{i=1}^n w_{k,i} \cdot \mathcal{N}(x, m_{k,i}, P_{k,i})| \leq \varepsilon \quad (2.5)$$

2.3.2 Les hypothèses de modèles gaussiens

Pour appliquer cet algorithme spécifique, le système doit répondre aux propositions suivantes :

- Chaque cible individuelle suit un modèle linéaire gaussien :

$$f(x|\zeta) = \mathcal{N}(x; F_{k-1}\zeta, Q_{k-1}) \quad (2.6)$$

$$g_k(z|x) = \mathcal{N}(z; Hx, R_k) \quad (2.7)$$

avec F_k la matrice de transition de l'état du système, Q_k la matrice de covariance du bruit de modèle, H la matrice de transformation de l'espace d'état vers l'espace des mesures et R_k la matrice de covariance du bruit de mesure.

- La probabilité de détection et de survie sont constantes sur toute la surface donnée

$$P_s(x) = P_s \quad (2.8)$$

$$P_d(x) = P_d \quad (2.9)$$

- L'intensité des cibles naissantes est un RFS modélisé par un mélange de gaussiennes de la forme :

$$\gamma_k(x) = \sum_{i=1}^{J_{k,i}^\gamma} w_{k,i}^\gamma \cdot \mathcal{N}\left(x; m_{k,i}^\gamma, P_{k,i}^\gamma\right) \quad (2.10)$$

où $w_{k,i}^\gamma$, $m_{k,i}^\gamma$ et $P_{k,i}^\gamma$ sont les paramètres de poids, de moyenne et de covariances des gaussiennes représentant les cibles naissantes ainsi que leur nombre $J_{k,i}^\gamma$.

- L'intensité *a posteriori* du RFS représentant l'ensemble des cibles sur la surface V_k peut s'écrire sous la forme d'un mélange de gaussiennes :

$$v_k(x) = \sum_{i=1}^{N_k^G} w_{k,i} \cdot \mathcal{N}(x; m_{k,i}, P_{k,i}) \quad (2.11)$$

où $w_{k,i}$, $m_{k,i}$ et $P_{k,i}$ sont les paramètres de poids, de moyenne et de covariance des gaussiennes, ainsi que leur nombre N_k^G .

De plus m_k est un vecteur d'état tel que :

$$m_{k,i} = [x_{k,i}, \dot{x}_{k,i}, y_{k,i}, \dot{y}_{k,i}]^T \quad (2.12)$$

où $(x_{k,i}, y_{k,i})$ correspond à la position and $(\dot{x}_{k,i}, \dot{y}_{k,i})$ à la vitesse d'une cible dans le repère cartésien.

2.3.3 Le filtre GM-CPHD

En combinant les équations de prédiction et de mise à jour du CPHD avec une forme d'intensité gaussienne, nous pouvons décrire un nouvel algorithme appelé Gaussian Mixture Cardinalized Probability Hypothesis Density ou GM-CPHD. Il a été proposé par Vo en 2006 [Vo 2006c, Vo 2006a, Vo 2007].

2.3.4 Équations de prédiction

L'équation de prédiction pour l'intensité présentée en (1.75) devient de la forme suivante :

$$v_{k|k-1}(x) = v_{S,k|k-1}(x) + \gamma_k(x) \quad (2.13)$$

avec γ_k l'intensité des cibles naissantes qui a été donnée dans l'équation 2.10 et $v_{S,k|k-1}(\cdot)$ l'intensité prédite des cibles survivantes telle que :

$$v_{S,k|k-1}(x) = P_s \sum_{i=1}^{J_{k-1}} w_{k-1,i} \cdot \mathcal{N}(x; Fm_{k-1,i}, FP_{k-1,i}F^T + Q) \quad (2.14)$$

Et la probabilité du nombre de cibles s'écrit, en considérant l'équation (1.84) de la manière suivante :

$$\forall n \in \mathbb{N}^*, \quad p_{k|k-1}(n) = \sum_{j=0}^n p_{\Gamma,k}(n-j) \sum_{l=j}^{\infty} C_j^l \cdot p_{k-1}(l) \cdot P_s^j \cdot (1-P_s)^{(l-j)} \quad (2.15)$$

avec $p_{\Gamma,k}(n)$ la probabilité d'avoir n cibles naissantes à l'itération k .

2.3.5 Équations de mise à jour

L'équation de mise à jour du nombre de cibles est la même que dans l'équation (1.86). Grâce aux hypothèses gaussiennes, les vraisemblances des jeux de mesures s'écrivent sous la forme suivante :

$$\Upsilon_k^u[w, Z](n) = \sum_{j=0}^{\min(|Z|, n)} (|Z| - j)! P_{\kappa}(|Z| - j) \cdot P_{j+u}^n \frac{(1 - P_d)^{n-(j+u)}}{\langle 1, w \rangle^{j+u}} e_j(\Xi_k(w, Z)) \quad (2.16)$$

où P_{j+u}^n désigne le coefficient de permutation de paramètres $(j+u, n)$ et avec :

$$\Xi_k(w, Z) = \left\{ \frac{\langle 1, \kappa_k \rangle}{\kappa_k(z)} P_d \cdot w^T \cdot q_k(z) : z \in Z \right\} \quad (2.17)$$

avec $w_{k|k-1}$ le vecteur représentant l'ensemble des poids accordés aux gaussiennes prédites tel que :

$$w_{k|k-1} = [w_{k|k-1,1}, \dots, w_{k|k-1, J_{k|k-1}}]^T \quad (2.18)$$

où $J_{k|k-1}$ est le nombre de pistes prédites.

La variable $q_k(z)$ représente l'ensemble des vraisemblances de la mesure z par rapport aux états prédits.

$$q_k(z) = [q_{k,1}(z), \dots, q_{k, J_{k|k-1}}(z)]^T \quad (2.19)$$

La vraisemblance d'une mesure par rapport à un état prédit j s'écrit de la manière suivante :

$$q_{k,j}(z) = \mathcal{N}(z, H \cdot m_{k|k-1,j}, R_k + HP_{k|k-1,j}H^T) \quad (2.20)$$

Finalement chaque gaussienne peut être mise à jour par l'estimation des paramètres suivants :

– le poids, issu des équations (1.90) et (2.17) :

$$w_{k,j}(z) = P_d \cdot w_{k|k-1,j} \cdot q_{k,j}(z) \frac{\langle \Upsilon_k^1[w_{k|k-1}, Z_k \setminus \{z\}], p_{k|k-1} \rangle}{\langle \Upsilon_k^0[w_{k|k-1}, Z_k], p_{k|k-1} \rangle} \cdot \frac{\langle 1, \kappa_k \rangle}{\kappa_k(z)} \quad (2.21)$$

– la position

$$m_{k,j}(z) = m_{k|k-1,j} + K_{k,j}(z - H m_{k|k-1,j}) \quad (2.22)$$

– la covariance

$$P_{k,j}(z) = P_{k|k-1,j} [Id + K_{k,j} H] \quad (2.23)$$

– le gain

$$K_{k,j}(z) = P_{k|k-1,j}^{(j)} H^T (H P_{k|k-1,j} H^T + R_k)^{-1} \quad (2.24)$$

L'équation de mise à jour pour la probabilité du nombre de cibles $p_{k|k}(n)$ s'obtient à partir de (1.86) en remplaçant $v_{k|k}$ par un mélange de gaussiennes, tel que $\forall n \in \mathcal{N}$:

$$p_{k|k}(n) = \frac{\Upsilon_k^0[w_{k|k-1}, Z_k](n) p_{k|k-1}(n)}{\langle \Upsilon_k^0[w_{k|k-1}, p_{k|k-1}] \rangle} \quad (2.25)$$

2.3.6 Implémentation

Dans cette partie, nous décrivons plus précisément certains détails de l'implémentation. Par ailleurs, afin de limiter la combinatoire, des heuristiques algorithmiques sont réalisées.

2.3.6.1 Les fenêtrages sur la position

Tout d'abord, afin de réduire le nombre d'hypothèses d'association cible/mesure, un fenêtrage statistique (*cf.* Partie 1.4.6.1) est réalisé autour de la position prédite $m_{k|k-1,i}$ d'une cible i pour ne conserver que les mesures statistiquement proches de celle-ci. On désigne par Z^* l'ensemble des mesures à prendre en compte qui est calculé tel que :

$$Z^* = \left\{ \forall i \in \{1, \dots, \hat{N}_k\}, (m_{k|k-1,i} - z) P_{k|k-1,i}^{-1} (m_{k|k-1,i} - z)^T < \gamma : z \in Z \right\} \quad (2.26)$$

avec $\{m_{k|k-1,i}\}_{1 \leq i \leq J_{k|k-1}}$ l'ensemble des positions prédites pour les gaussiennes et $P_{k|k-1,i}$ la matrice de covariance de l'erreur associée et γ le seuil de validation.

Par conséquent, le calcul de la mesure de vraisemblance Ξ est modifiée :

$$\Xi_k(w^*, Z^*) = \left\{ \frac{\langle 1, \kappa_k \rangle}{\kappa_k(z)} P_d \cdot w_z^T \cdot q_k^*(z) : z \in Z^* \right\} \quad (2.27)$$

où $q_k^*(z) = \{q_{k,i}(z)\}_{\forall i \in \{1, \dots, N_z\}}$ avec N_z le nombre de cibles associées à la mesure z et w_z l'ensemble des poids des gaussiennes associés à la mesure z .

L'utilisation d'un fenêtrage statistique pour limiter la combinatoire a également été proposé par Zhang *et al.* dans [Zhang 2009].

2.3.6.2 Le calcul de la fonction symétrique élémentaire

La fonction élémentaire symétrique $e_j(Z)$ d'ordre j d'une séquence finie d'éléments Z , utilisée en (2.16), est définie de la manière suivante :

$$e_j(Z) = \sum_{S \subseteq Z, |S|=j} \prod_{\zeta \in S} \zeta \quad (2.28)$$

A titre d'exemple, considérons l'ensemble $X = \{x_1, x_2, x_3, x_4\}$. Le produit symétrique élémentaire se calcule de la manière suivante

$$\begin{cases} e_0 = 1 \\ e_1 = x_1 + x_2 + x_3 + x_4 \\ e_2 = x_1x_2 + x_1x_3 + x_1x_4 + x_2x_3 + x_2x_4 + x_3x_4 \\ e_3 = x_1x_2x_3 + x_1x_2x_4 + x_1x_3x_4 + x_2x_3x_4 \\ e_4 = x_1x_2x_3x_4 \end{cases} \quad (2.29)$$

La fonction symétrique élémentaire $\{e_i\}_{i=1}^4$ est maximale quand i correspond au nombre d'éléments x_j qui sont supérieurs à 1. Dans l'équation (2.25), la variable notée $\Upsilon_k^0[w_k|k-1, Z_k](n)$ est donc maximale pour n est égale au nombre de mesures très vraisemblables auprès d'au moins une gaussienne prédite.

Le calcul de la fonction symétrique élémentaire est très coûteux en temps si l'ensemble des combinaisons d'association est manuellement calculé. En utilisant les formules suivantes récursivement, la complexité est seulement de $o(N^2)$ avec N la taille de l'ensemble $X = \{x_1, \dots, x_N\}$ dont est calculée la fonction symétrique élémentaire. La première étape est l'initialisation :

$$\begin{cases} \forall j \in \{1, \dots, N\}, & \sigma_{1,j} = x_1 + \dots + x_j \\ \forall i \in \{2, \dots, N\}, & \sigma_{i,1} = 0 \end{cases} \quad (2.30)$$

Ensuite récursivement, les autres coefficient $\sigma_{i,j}$ sont calculés de la manière suivante :

$$\forall (i, j) \in \{2, \dots, N\}, \quad \sigma_{i,j} = \sigma_{i,j-1} + x_j \sigma_{i-1,j-1} \quad (2.31)$$

Finalement, les coefficients $\{e_j\}_{j \in \{1, \dots, N\}}$ sont obtenus tels que :

$$\forall j \in \{1, \dots, N\}, \quad e_j = \sigma_{j,N} \quad (2.32)$$

Plus d'explications sur cette technique sont disponibles dans un livre de Goodman sur les mathématiques de la fusion de données [Goodman 1997].

2.3.7 L'évaluation du nombre de cibles

De manière exacte, le nombre de cibles estimé est donné par la formule suivante :

$$\hat{N}_k = \sum_{n=1}^{\infty} n \cdot p_k(n) \quad (2.33)$$

Cette équation nous oblige à introduire un paramètre supplémentaire N_{max} qui détermine quel nombre maximum de cibles sont considérées.

Cependant, cette approche nous donne un nombre réel alors que nous souhaitons obtenir un nombre entier. L'idée est donc finalement de prendre \hat{N}_k égal à l'indice maximal de $p_k(n)$

$$\hat{N}_k = \operatorname{argmax}_{n \in \{1, \dots, N_{max}\}} p_k(n) \quad (2.34)$$

2.3.7.1 Naissance des cibles

Dans toutes les publications de Vo sur le GM-CPHD [Vo 2006c, Vo 2006a], l'auteur suppose qu'il connaît les positions de départ possibles pour les cibles. Cette hypothèse facilite donc grandement la détection de nouvelles cibles mais est très réductrice car il n'est pas évident que toutes les cibles apparaissent aux mêmes endroits. Ulmke [Ulmke 2007] a une approche légèrement différente. Il crée un modèle gaussien de naissance centré au milieu de la zone d'observation avec une ellipse de covariance très grande puisque couvrant l'ensemble de la zone. Mais cette approche ne permet pas d'initialiser la vitesse et revient à considérer toutes les mesures comme des cibles naissantes potentielles.

Une première approche très intuitive aurait pu consister à considérer chaque mesure non associée à une piste comme une possible cible naissante. Mais cette approche, malgré le fenêtrage vitesse, donne naissance à de trop nombreuses fausses pistes. Aussi, avons nous limité les hypothèses de nouvelles cibles aux mesures associées à aucune piste à l'instant k et proche statistiquement d'une autre mesure qui à l'instant précédent $k - 1$ n'était également associée à aucune piste. Cette méthode donne des résultats satisfaisants au niveau des fausses pistes. De plus, elle permet d'obtenir, dès la première itération une approximation de la vitesse de la cible.

2.3.7.2 Réduction du nombre de gaussiennes

Si aucune méthode de réduction du nombre de gaussiennes n'est utilisée, ce nombre va croître exponentiellement en augmentant la combinatoire d'une part, et en augmentant la probabilité d'associer une gaussienne avec une fausse alarme d'autres parts. Une étape de *merging* et une étape de *pruning* sont donc effectuées afin que le nombre de gaussiennes reste stable.

L'étape de *pruning* consiste à supprimer les gaussiennes dont les poids sont inférieurs à un certain seuil U_1 .

L'étape de *merging* consiste à appairer les gaussiennes qui sont proches statistiquement en une seule gaussienne. Deux gaussiennes sont proches statistiquement si et seulement si la distance statistique séparant leurs deux pics est inférieur à un certain seuil U_2 .

Finalement, le pseudo code de réduction du nombre de gaussiennes pour le du GM-CPHD est décrit dans le pseudo-algorithme décrit dans la partie 2.3.7.3.

2.3.7.3 Pseudo code de réduction du nombre de gaussiennes

Algorithme 2.3.1 Étape de *pruning* et *merging* du GM-CPHD

0: **Input** :

- $\{w_{k,i}, m_{k,i}, P_{k,i}\}_{i=1}^{N_k^G}$: ensemble des gaussiennes
- U_1 : seuil de poids pour la suppression
- J_{max} : le nombre de gaussiennes final maximum
- U_2 : la distance statistique de suppression

1: $I = \{i = 1, \dots, J_k | w_{k,i} > U_1\}$

2: $l = 0$

3: **repeat**

4: $l := l + 1$

5: **if** $l > J_{max}$ **then**

```

6:   break
7: end if
8:    $j := \operatorname{argmax}_{i \in I} w_{k,i}$ 
9:    $L := \{i \in I | (m_{k,i} - m_{k,j})^T (P_{k,i})^{-1} (m_{k,i} - m_{k,j}) < U_2\}$ 
10:   $\tilde{w}_{k,l} = \sum_{i \in L} w_{k,i}$ 
11:   $\tilde{m}_{k,l} = \frac{1}{\tilde{w}_{k,l}} \sum_{i \in L} w_{k,i} m_{k,i}$ 
12:   $\tilde{P}_{k,l} = \frac{1}{\tilde{w}_{k,l}} \sum_{i \in L} w_{k,i} (m_{k,i} - m_{k,l})(m_{k,i} - m_{k,l})^T$ 
13:   $I := I \setminus L$ 
14: until  $I = \phi$ 

```

Output : $\{\tilde{w}_{k,i}, \tilde{m}_{k,i}, P_{k,i}\}_{i=1}^{\tilde{N}_k^{\mathcal{G}}}$: l'ensemble réduit des gaussiennes

2.4 Labellisation du filtre CPHD

2.4.1 Problématique

Une piste est une suite d'états estimés décrivant la dynamique d'une cible. Le but du pistage est donc de fournir à chaque itération k un ensemble de pistes \mathcal{T}_k correspondant à l'ensemble des cibles comme défini en (1.13) et (1.14).

Comme présenté dans les parties 1.4.4.3 et 2.3.3, le filtre GM-CPHD [Vo 2007] fournit à chaque itération k un ensemble fini de $N_k^{\mathcal{G}}$ gaussiennes. Cet ensemble modélise la fonction d'intensité $v_{k|k}$ de l'ensemble des cibles X_k sur la zone d'observation V_k , telle qu'en un point x de V_k :

$$v_{k|k}(x) = \sum_{i=1}^{N_k^{\mathcal{G}}} w_{k,i}^{\mathcal{G}} \mathcal{N}(x, m_{k,i}^{\mathcal{G}}, P_{k,i}^{\mathcal{G}}) \quad (2.35)$$

où $(w_{k,i}^{\mathcal{G}}, m_{k,i}^{\mathcal{G}}, P_{k,i}^{\mathcal{G}})$ sont le poids, la position moyenne et la covariance de la gaussienne et $N_k^{\mathcal{G}}$ est le nombre de gaussiennes à l'instant k .




Fig. 2.3 – Problème de labellisation du filtre CPHD

Pour la suite, nous écrivons l'ensemble des gaussiennes \mathcal{G}_k à l'itération k de la manière suivante :

$$\mathcal{G}_k = \left\{ w_{k,i}^{\mathcal{G}}, m_{k,i}^{\mathcal{G}}, P_{k,i}^{\mathcal{G}} \right\}_{i \in \{1, \dots, N_k^{\mathcal{G}}\}} = \left\{ \mathcal{G}_{k,1}, \dots, \mathcal{G}_{k,N_k^{\mathcal{G}}} \right\} \quad (2.36)$$

où $N_k^{\mathcal{G}}$ est le nombre de gaussiennes ($\neq \hat{N}_{k|k}$) à l'itération k .

Dans notre problème d'identification des cibles, il faut choisir, parmi l'ensemble des gaussiennes, lesquelles peuvent être associées à une piste comme illustré par la figure 2.3. À cette fin, nous utilisons une technique de labellisation afin de fournir à chaque itération k un ensemble de pistes \mathcal{T}_k^{PHD} issu de \mathcal{G}_k les plus fiables possibles. Ces pistes sont ensuite utilisées comme une des entrées lors de l'étape d'estimation hybride présentées en figure 2.2.

2.4.2 Approches existantes pour la labellisation

Ce problème n'est pas du tout abordé dans la version classique du GM-CPHD. Quelques auteurs ont étudié le problème. Clark *et al.*, dans le cadre du GM-PHD [Clark 2006b], proposent d'assigner à chaque pic de gaussienne un label et de prendre comme piste les gaussiennes ayant un poids supérieur à un certain seuil. Mais si une cible est non-détectée, le poids de la gaussienne correspondant à cette cible réelle tombe en dessous du seuil minimal. La solution consiste à conserver cette gaussienne ainsi que son label associé et si à l'itération suivante, le poids de la gaussienne repasse au dessus du seuil, alors la trajectoire de la piste est confirmée *a posteriori*. Cependant, cette méthode ne peut pas être appliquée telle quelle car elle ne prend pas en considération le nombre estimé de cibles $\hat{N}_{k|k}$. En effet, nous utilisons la version cardinalisée de l'algorithme qui existe depuis 2006 [Mahler 2006, Mahler 2007b] car elle permet de fournir à chaque itération k une très bonne estimation $\hat{N}_{k|k}$ du nombre de cibles présentes par étude de la densité de probabilité du nombre de cibles.

Dans d'autres travaux [Clark 2007], Clark *et al.* proposent d'autres solutions de labellisation avec le SM-PHD. La première solution consiste à attribuer un label à chaque particule et la méthode du *k-means* est utilisée pour attribuer un label aux pics de gaussiennes. La deuxième solution consiste à sélectionner la meilleure combinaison d'association entre pics et pistes prédites. Cette solution est finalement très proche de celle de Lin [Lin 2006]. Cependant, elle se limite à une approche du plus proche voisin lorsque le nombre de pistes est trop important.

Une dernière solution est proposée par Panta *et al.* [Panta 2009] pour le GM-PHD. Elle consiste à élaborer un arbre d'hypothèses pour les associations gaussiennes/pistes dont la gestion de l'arborescence est inspirée du MHT. Cette dernière solution ne prend pas en compte l'estimation du nombre de cibles et n'est donc pas adaptée.

Les techniques existantes ne sont pas exactement adaptées au filtre GM-CPHD. Nous décrivons donc à présent la technique de labellisation que nous avons élaborée pour le filtre GM-CPHD.

2.4.3 Matrice d'association

L'objectif de la labellisation est de choisir les pistes \mathcal{T}_k à l'itération k parmi l'ensemble des gaussiennes \mathcal{G}_k , connaissant les pistes \mathcal{T}_{k-1} à l'itération précédente.

Afin de faciliter la compréhension du lecteur, l'usage des notations est illustré par un exemple simple présenté en figure 2.4. Dans cet exemple, quatre pistes $\{\mathcal{T}_{k,i}\}_{i=1}^4$, chacune constituée de trois états estimés consécutifs $\{\hat{x}_{k-k_0,i}\}_{k_0=1}^3$, sont observées. Leurs états, $\{\hat{s}_{k|k-1,i}\}_{i=1}^4$, sont prédits à l'itération k ainsi que leurs covariances, représentées sur le graphique par des ellipses. Finalement, à l'itération k , on observe 6 mesures qui donnent naissance à un ensemble de 6 gaussiennes $\{\mathcal{G}_{k,j}\}_{j=1}^6$. L'objectif, dans cette partie, est d'identifier les gaussiennes comme la continuité d'une piste existante, une nouvelle piste ou une fausse alarme.

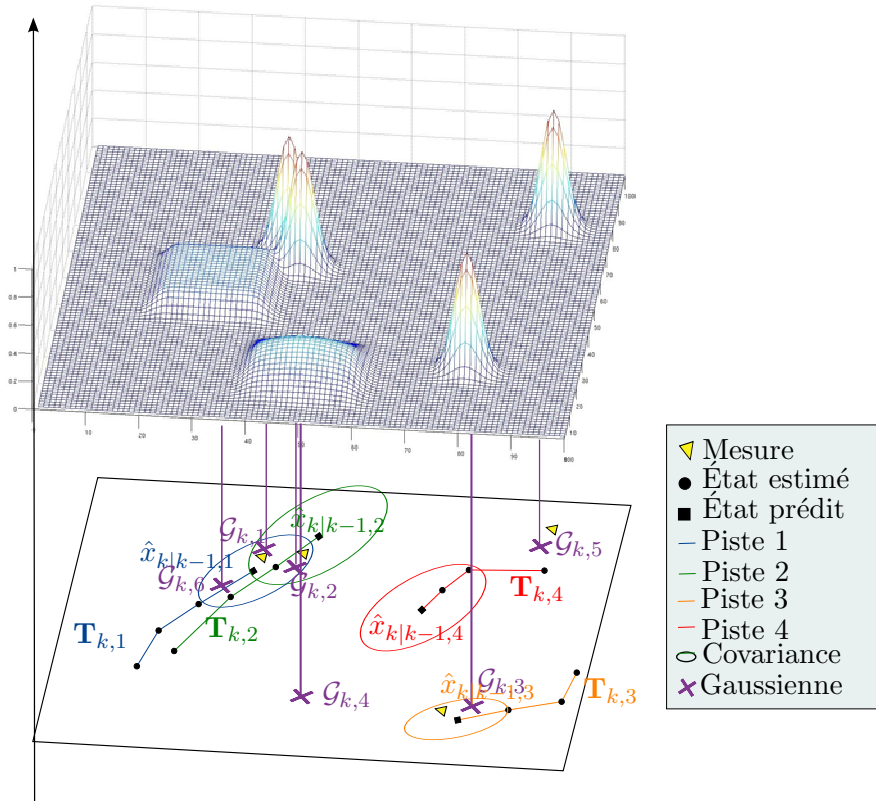


Fig. 2.4 – Un exemple de labellisation pour le filtre GM-CPHD $\hat{N}_{k-1|k-1} = 4$, $\hat{N}_{k|k} = 4$, $w_{k,1} = 0.92$, $w_{k,2} = 0.89$, $w_{k,3} = 0.95$, $w_{k,4} = 0.12$, $w_{k,5} = 0.96$, $w_{k,6} = 0.02$

Or, sélectionner les \mathcal{T}_k à l'itération k parmi l'ensemble des gaussiennes \mathcal{G}_k revient à calculer la meilleure matrice d'association, notée \mathbf{A}_k , selon des critères définis dans cette section.

2.4.3.1 Principe

Soit \mathbf{A}_k la matrice binaire qui représente la combinaison d'association sélectionnée entre l'ensemble des gaussiennes \mathcal{G}_k et l'ensemble des pistes \mathcal{T}_k de taille $\hat{N}_{k|k} \times N_k^{\mathcal{G}}$ telle que :

$$\forall (m, n) \leq (\hat{N}_{k|k}, N_k^{\mathcal{G}}), \quad \mathbf{A}_k(m, n) = \begin{cases} 1 & \text{si } \mathcal{G}_{k,n} \text{ est associée à } \mathcal{T}_{k,m} \\ 0 & \text{sinon} \end{cases} \quad (2.37)$$

Sachant qu'une piste est associée au plus à une gaussienne, la matrice \mathbf{A}_k satisfait les critères suivants :

$$\left\{ \begin{array}{l} \sum_{m=1}^{\hat{N}_{k|k}} \sum_{n=1}^{N_k^{\mathcal{G}}} \mathbf{A}_k(m, n) = \hat{N}_{k|k} \\ \forall n \leq N_k^{\mathcal{G}}, \quad \sum_{m=1}^{\hat{N}_{k|k}} \mathbf{A}_k(m, n) \leq 1 \\ \forall m \leq \hat{N}_{k|k}, \quad \sum_{n=1}^{N_k^{\mathcal{G}}} \mathbf{A}_k(m, n) = 1 \end{array} \right. \quad (2.38)$$

L'enjeu de la labellisation est de sélectionner cette matrice \mathbf{A}_k parmi l'ensemble $A_k = \{A_{k,a}\}_{a=1}^{N_a}$ des N_a combinaisons d'associations possibles à l'itération k . Le choix doit être fait selon deux critères que nous avons choisis :

- Maximiser la somme des poids de l'ensemble des gaussiennes associées à des pistes : plus le poids d'une gaussienne est proche de 1, plus la présence d'une cible est vraisemblable.
- Minimiser la distance entre une gaussienne et sa piste prédite associée. Ce deuxième critère intervient lorsque plusieurs matrices d'associations ont le même poids global et ne sont donc pas discriminables au sens du poids global.

2.4.3.2 Élaboration de toutes les combinaisons d'associations possibles

Nous souhaitons donc déterminer l'ensemble A_k de toutes les combinaisons d'associations possibles à l'itération k . Elles doivent satisfaire les critères décrit pour \mathbf{A}_k selon (2.38). De plus, afin de limiter la combinatoire, un fenêtrage statistique est réalisé autour de la position prédite des pistes pour réduire le nombre de gaussiennes associables à une piste. La matrice d'association globale \tilde{A}_k décrit les associations possibles et s'écrit donc :

$$\tilde{A}_k(m, n) = \begin{cases} 1 & \text{si } \mathcal{G}_{k,n} \text{ peut être associée à } \mathcal{T}_{k|k-1,m} \\ 0 & \text{sinon} \end{cases} \quad (2.39)$$

Une gaussienne peut être associée à une piste si elle satisfait le test de validation (fenêtrage statistique) comme décrit en (1.103).

Application à l'exemple de la figure 2.4 En réalisant un fenêtrage statistique autour des positions prédites des quatre cibles $\hat{x}_{k|k-1,j}$, $\forall j \leq 4$, on obtient la matrice d'association globale \tilde{A}_k de taille 4×6 car le nombre de gaussiennes $N_k^{\mathcal{G}} = 6$ et le nombre estimé de cibles $\hat{N}_{k|k} = 4$ telle que :

$$\tilde{A}_k = \begin{bmatrix} 1 & 1 & 0 & 0 & 0 & 1 \\ 1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (2.40)$$

On observe ainsi que les gaussiennes $\mathcal{G}_{k,1}$ et $\mathcal{G}_{k,2}$ peuvent toutes deux être associées aux pistes $\mathcal{T}_{k,1}$ et $\mathcal{T}_{k,2}$, tandis que les gaussiennes $\mathcal{G}_{k,4}$ et $\mathcal{G}_{k,5}$ n'appartiennent à aucune ellipse de covariance prédite des pistes.

2.4.3.3 Initialisation et suppression de pistes

Telle qu'elle est décrite, la matrice \tilde{A} est de la taille $\hat{N}_k \times N_k^G$. Or si $\hat{N}_{k|k} > \hat{N}_{k-1|k-1}$, il faut initialiser une ou plusieurs nouvelles pistes. Chaque gaussienne est alors considérée comme une nouvelle piste potentielle. Dans la matrice \tilde{A}_k , cela signifie que l'on ajoute une ligne contenant uniquement des 1 :

$$\forall m \in \{1, \dots, N_k^G\}, \forall l \in \{\hat{N}_{k-1|k-1} + 1, \dots, \hat{N}_{k|k}\}, \quad \tilde{A}(m, l) = 1 \quad (2.41)$$

Concernant la suppression de pistes, deux cas de figure sont possibles. Tout d'abord, si on a $\hat{N}_{k|k} < \hat{N}_{k-1|k-1}$, alors il faut supprimer une ou plusieurs pistes. Le poids des gaussiennes ne peut pas être un critère de suppression de piste car une piste associée à une non détection risque d'être faussement supprimée. Ce sont donc les pistes ayant le score le plus faible qui sont supprimées. Deuxièmement, si une piste n'est associée à aucune gaussienne alors elle est supprimée.

Ensuite, l'ensemble $A_k = \{A_{k,a}\}_{a=1}^{N_a}$ des combinaisons d'associations possibles à l'itération k est calculé à partir de la matrice \tilde{A}_k et des contraintes définies en (2.38)

Application à l'exemple de la figure 2.4 Dans l'exemple, le nombre estimé de cibles reste le même : $\hat{N}_{k|k} = \hat{N}_{k-1|k-1} = 4$. Cependant, la piste $\mathbf{T}_{k,4}$ n'est associée à aucune gaussienne. Elle est donc supprimée en imposant à 1 tous les éléments de la ligne correspondante. La matrice d'association globale \tilde{A}_k devient donc :

$$\tilde{A}_k = \begin{bmatrix} 1 & 1 & 0 & 0 & 0 & 1 \\ 1 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 1 & 1 & 1 & 1 & 1 & 1 \end{bmatrix} \quad (2.42)$$

de telle façon à ce que chaque gaussienne puisse être considérée comme une piste naissante potentielle.

À partir de la matrice d'association globale, les matrices d'association $A_{k,a}$ peuvent être calculées. Elles correspondent à une combinaison d'association piste/gaussienne satisfaisant les critères : « Une piste est associée au plus à une gaussienne ». Elles s'écrivent alors , $\forall a \leq N_a$:

$$\begin{aligned} A_{k,1} &= \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix} & A_{k,2} &= \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix} \\ A_{k,3} &= \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} & A_{k,4} &= \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix} \\ A_{k,5} &= \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix} & A_{k,6} &= \begin{bmatrix} 0 & 1 & 0 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 \end{bmatrix} \end{aligned}$$

$$A_{k,7} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix} \quad A_{k,8} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 \end{bmatrix}$$

$$A_{k,9} = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 1 & 0 & 0 & 0 & 0 & 0 \end{bmatrix}$$

Nous décrivons donc dans les deux parties suivantes les matrices de poids et de coût (lié à la distance entre une gaussienne et sa piste prédite associée), ainsi que le calcul du score d'une piste (utilisé pour la suppression de pistes).

2.4.4 Poids global d'une association

La matrice de poids W_k se calcule de la façon suivante :

$$\forall n \leq N_k^{\mathcal{G}}, \quad W_k(:, n) = w_{k,i}^{\mathcal{G}} \quad (2.43)$$

où $W_k(:, n)$ désigne la $n^{\text{ème}}$ colonne de la matrice W_k et $w_{k,i}^{\mathcal{G}}$ est le poids de la gaussienne $\mathcal{G}_{k,i}$ (autrement dit l'intensité du pic).

Le poids global $W_{k,a}^{\mathcal{G}}$ d'une association a peut être calculé comme la somme des poids des gaussiennes qui sont associées à des pistes tels que :

$$W_{k,a}^{\mathcal{G}} = \sum_{m=1}^{\hat{N}_k} \sum_{n=1}^{N_k^{\mathcal{G}}} A_{k,a}(m, n) \cdot W_k(m, n) \quad (2.44)$$

En présence de pistes proches, la combinaison d'associations qui maximise le poids global n'est peut être pas unique. Finalement, la ou les matrices d'association qui maximisent le poids global A_k^* peuvent s'écrire de la façon suivante :

$$A_k^* = \underset{A_{k,a}}{\operatorname{argmax}} W_{k,a}^{\mathcal{G}} \quad (2.45)$$

Donc si A_k^* est unique, alors $\mathbf{A}_k = A_k^*$. Sinon, il faut introduire la distance entre les pistes prédites et les gaussiennes pour choisir une association parmi celles contenues dans A_k^* .

Application à l'exemple de la figure 2.4 La matrice de poids W_k s'écrit :

$$W_k = \begin{bmatrix} 0.92 & 0.89 & 0.95 & 0.12 & 0.96 & 0.02 \\ 0.92 & 0.89 & 0.95 & 0.12 & 0.96 & 0.02 \\ 0.92 & 0.89 & 0.95 & 0.12 & 0.96 & 0.02 \\ 0.92 & 0.89 & 0.95 & 0.12 & 0.96 & 0.02 \end{bmatrix} \quad (2.46)$$

Ensuite, on multiplie terme à terme cette matrice avec les matrices d'association $A_{k,a}$. On obtient alors les poids globaux $\left\{ W_{k,a}^{\mathcal{G}} \right\}_{a=1}^9$ suivants :

$$W_{k,1}^{\mathcal{G}} = 2.88, \quad W_{k,2}^{\mathcal{G}} = 3.72, \quad W_{k,3}^{\mathcal{G}} = 2.78, \quad W_{k,4}^{\mathcal{G}} = 2.88, \quad W_{k,5}^{\mathcal{G}} = 3.72,$$

$$W_{k,6}^{\mathcal{G}} = 2.78, \quad W_{k,7}^{\mathcal{G}} = 1.98, \quad W_{k,8}^{\mathcal{G}} = 1.98, \quad W_{k,9}^{\mathcal{G}} = 2.78$$

Finalement, les matrices d'association qui maximisent le poids global A_k^* sont les matrices $W_{k,1}^{\mathcal{G}}$ et $W_{k,4}^{\mathcal{G}}$, telles que

$$W_{k,2}^{\mathcal{G}} = W_{k,5}^{\mathcal{G}} = 3.72$$

Par conséquent, A_k^* n'est pas unique et on ne peut pas discriminer ses deux combinaisons d'association. On s'intéresse donc maintenant au coût d'association.

2.4.5 La matrice de coût

De façon très similaire à la matrice de poids, la matrice de coût C_k se calcule de la façon suivante, $\forall m \in \{1, \dots, N_k^{\mathcal{G}}\}$, $\forall n \in \{1, \dots, \hat{N}_{k|k}\}$:

$$C_k(m, n) = c(m, n) \quad (2.47)$$

avec $c(m, n)$ le coût d'association de la piste prédite m et la gaussienne n . Il s'écrit comme le logarithme négatif du ratio de la vraisemblance :

$$c(m, n) = -\ln \left(\frac{P_d \cdot g(\mathcal{G}_{k,n} | \hat{x}_{k|k-1,j})}{\beta_{fa}} \right) \quad (2.48)$$

avec $g(\mathcal{G}_{k,n} | \hat{x}_{k|k-1,j})$ la vraisemblance de la position de la gaussienne par rapport à la position prédite $\hat{x}_{k|k-1,j}$ de la piste j .

Le coût global $C_{k,a}^{\mathcal{G}}$ d'une association a à l'itération k peut être calculé comme la somme des coûts des associations gaussiennes/pistes tel que :

$$C_{k,a}^{\mathcal{G}} = \sum_{m=1}^{\hat{N}_k} \sum_{n=1}^{N_k^{\mathcal{G}}} A_{k,a}(m, n) \cdot C_k(m, n) \quad (2.49)$$

Finalement, la combinaison d'association qui minimise le coût d'association peut être déterminée de manière unique telle que :

$$\mathbf{A}_k = \underset{A_k^*}{\operatorname{argmin}} C_{k,a}^{\mathcal{G}} \quad (2.50)$$

Application à l'exemple de la figure 2.4 La matrice de coût C_k s'écrit telle que :

$$C_k = \begin{bmatrix} c(1,1) & c(1,2) & c(1,3) & c(1,4) & c(1,5) & c(1,6) \\ c(2,1) & c(2,2) & c(2,3) & c(2,4) & c(2,5) & c(2,6) \\ c(3,1) & c(3,2) & c(3,3) & c(3,4) & c(3,5) & c(3,6) \\ c(4,1) & c(4,2) & c(4,3) & c(4,4) & c(4,5) & c(4,6) \end{bmatrix}$$

Le but ici n'est pas de calculer exactement le coût ; pour discriminer $W_{k,2}^{\mathcal{G}}$ et $W_{k,5}^{\mathcal{G}}$, on va choisir la combinaison qui minimise la somme des distances entre les gaussiennes $\mathcal{G}_{k,1}$ et $\mathcal{G}_{k,2}$ avec les positions prédites des pistes $\hat{x}_{k|k-1,1}$ et $\hat{x}_{k|k-1,2}$. Or,

$$d(\mathcal{G}_{k,1}, \hat{x}_{k|k-1,1}) + d(\mathcal{G}_{k,2}, \hat{x}_{k|k-1,2}) < d(\mathcal{G}_{k,1}, \hat{x}_{k|k-1,2}) + d(\mathcal{G}_{k,2}, \hat{x}_{k|k-1,1})$$

Par conséquent, c'est la matrice d'association 1 qui est choisie telle que :

$$\mathbf{A}_k = A_{k,1}$$

2.5 Optimisation de l'algorithme de labellisation

Le calcul littéral de la matrice d'association qui nous fournit la matrice de poids maximal et la matrice de coût minimal n'est combinatoirement pas possible. Il s'agit d'un problème d'optimisation, résolu dans ce cas par l'énumération d'un certain nombre de règles empiriques permettant de réduire le nombre d'hypothèses d'association d'une gaussienne à une piste et inversement.

L'algorithme de calcul de l'ensemble des matrices A_k que nous proposons est décrit dans cette partie. Il est illustré par le pseudo-code présenté en figure 2.5.

Dans un premier temps la matrice de poids des gaussiennes \tilde{W}_k est triée par ordre de poids décroissant. Les colonnes, correspondant à chacune des gaussiennes, sont ensuite traitées les unes après les autres en se basant sur le fait que les premières colonnes sont celles ayant le poids le plus fort. Pour chaque colonne l , s'il n'y a qu'un seul élément non vide, c'est à dire une seule piste associable à la gaussienne l dans la matrice d'association globale triée correspondante et que cet élément n'a pas encore été traité auparavant, alors cet élément est l'association qui va donner le poids le plus fort. Ainsi la piste l est associée à l'élément unique de cette colonne et l'élément correspondant de la matrice \mathbf{A}_k est initialisé à 1. Si un élément de la matrice \mathbf{A}_k est initialisé à 1, alors la ligne correspondante est supprimée puisqu'une piste est associée au plus à un élément et ce, toujours afin de limiter la combinatoire. Si la colonne l contient plusieurs éléments, le nombre d'éléments et l'indice de ces éléments sont retenus, jusqu'à ce qu'une ou plusieurs autres colonnes permettent de trouver autant d'éléments (correspondant à des pistes) que de colonnes traitées (correspondant à des gaussiennes). Si tel est le cas, alors, la combinaison partielle d'association d'une piste à une colonne donnant le poids le plus fort est cherchée et si les combinaisons ne sont pas maximisées au niveau du poids alors la discrimination de la combinaison d'association des pistes aux gaussiennes se fait par minimisation du coût. Si arrivé à la dernière colonne, le nombre d'éléments traités n'est toujours pas égal au nombre de colonnes retenues, alors la combinaison qui maximise le poids est cherchée en sachant qu'une ou plusieurs pistes pourront n'être associées à aucune gaussienne.

Application à l'exemple de la figure 2.4 Avec l'exemple traité, il a fallu calculer les critères pour neuf matrices d'association possibles. Avec l'optimisation, l'opération de labellisation est réduite à seulement quelques étapes.

Ainsi, on commence par trier la matrice de poids global W_k par ordre de poids décroissant telle que :

$$\tilde{W}_k = \begin{bmatrix} 0.96 & 0.95 & 0.92 & 0.89 & 0.12 & 0.02 \\ 0.96 & 0.95 & 0.92 & 0.89 & 0.12 & 0.02 \\ 0.96 & 0.95 & 0.92 & 0.89 & 0.12 & 0.02 \\ 0.96 & 0.95 & 0.92 & 0.89 & 0.12 & 0.02 \end{bmatrix}$$

On retient à l'aide d'une liste $o = [5 \ 3 \ 1 \ 2 \ 4 \ 6]$ l'ordre dans lequel les colonnes (les gaussiennes) sont triées. On permute les colonnes du coût global C_k et de la matrice d'association globale \tilde{A}_k de la même manière.

Finalement, en multipliant terme à terme les matrices de poids \tilde{W}_k et d'association

$\tilde{A}_k(:, o)$, on obtient la matrice \check{A} telle que :

$$\check{A} = \begin{bmatrix} 0 & 0 & 0.92 & 0.89 & 0 & 0.02 \\ 0 & 0 & 0.92 & 0.89 & 0 & 0 \\ 0 & 0.95 & 0 & 0 & 0 & 0 \\ 0.96 & 0.95 & 0.92 & 0.89 & 0.12 & 0.02 \end{bmatrix}$$

L'objectif est de maximiser, le poids global. Par conséquent, maintenant que la matrice est triée par ordre de poids décroissant, on peut traiter les cas de chaque colonne les unes après les autres. On traite donc la colonne 1. Celle-ci ne contient qu'un seul élément non nul. Cela signifie que la gaussienne $\mathcal{G}_{k,o(1)}$ ne peut être associée qu'à la piste $\mathcal{T}_{k,4}$ qui est la nouvelle piste. On élimine ensuite la colonne 1 et la ligne 4. Par ailleurs, les lignes et les colonnes qui ne contiennent que des 0 sont supprimées. Ainsi, la matrice \check{A} devient :

$$\check{A} = \begin{bmatrix} 0 & 0.92 & 0.89 & 0 & 0.02 \\ 0 & 0.92 & 0.89 & 0 & 0 \\ 0.95 & 0 & 0 & 0 & 0 \end{bmatrix} \quad (2.51)$$

On retient les indices de lignes et de colonnes traitées et supprimées de manière à instancier la matrice \mathbf{A}_k (non triée) telle que :

$$\mathbf{A}_k = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix}$$

L'opération est répétée de manière itérative, tant que la matrice \check{A} n'est pas vide. Ainsi, la colonne traitée ne contient encore qu'un élément, par conséquent la matrice \mathbf{A}_k est directement instantiée et la matrice \check{A} devient :

$$\check{A} = \begin{bmatrix} 0.92 & 0.89 & 0 & 0.02 \\ 0.92 & 0.89 & 0 & 0 \end{bmatrix} \quad \mathbf{A}_k = \begin{bmatrix} 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix}$$

Pour l'itération suivante, on voit que la première colonne contient deux éléments non nuls. On va donc chercher la colonne suivante. Le nombre de colonnes traitées est ainsi égal au nombre de lignes contenant des éléments non nuls. On peut donc chercher la meilleure combinaison pour ces deux colonnes. On utilise ici le cout car le poids global n'est pas discriminant. La matrice \mathbf{A}_k est instanciée. Toutes les lignes sont traitées. L'opération de recherche de la matrice d'association optimale est terminée et on a :

$$\mathbf{A}_k = \begin{bmatrix} 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix}$$

Ainsi, en trois itérations seulement, on a calculé de manière optimale la matrice d'association optimale \mathbf{A}_k , tandis que sans cette optimisation, on aurait du calculer les 9 matrices d'associations possible avant de sélectionner \mathbf{A}_k . Bien entendu, l'exemple présenté est très simple. Dans des conditions réelles, le gain est certain.

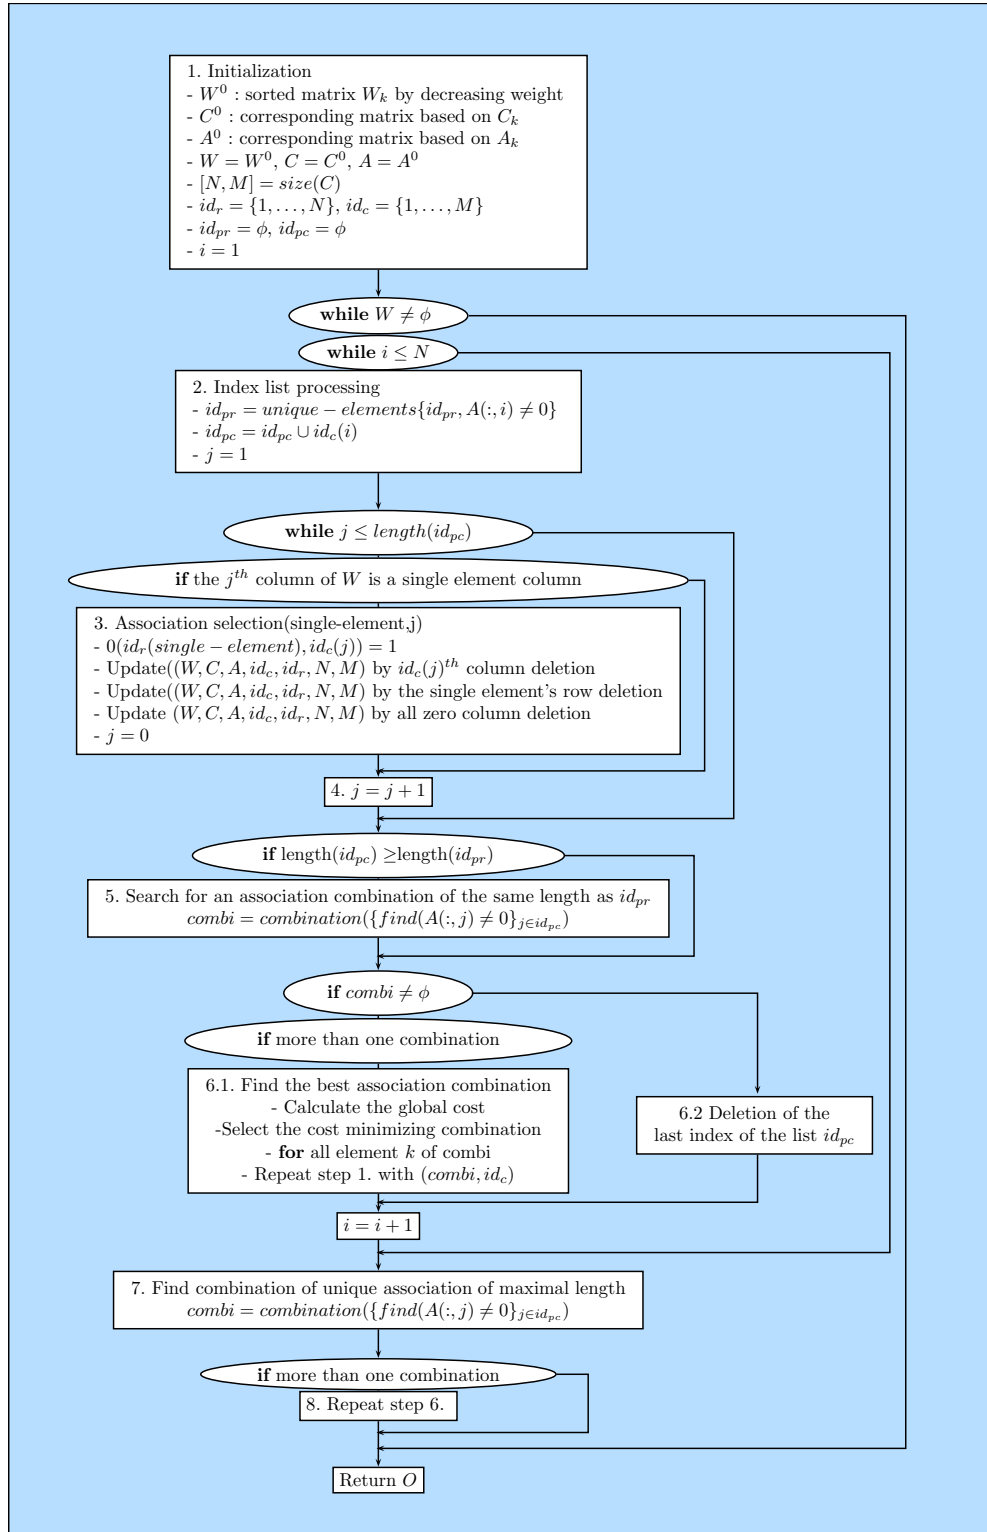


Fig. 2.5 – Schéma fonctionnel de la labellisation du GM-CPHD

Conclusion

Nous avons créé un algorithme hybride performant qui tire effectivement avantage des deux algorithmes GM-CPHD et IMM-MHT sélectionnés parmi les techniques classiques de pistage. Il combine ainsi la précision de l'estimation de l'IMM-MHT avec la précision de l'estimation du nombre de cibles du GM-CPHD. Comme nous le verrons lors des tests, les performances en terme de précision de l'estimation de l'état des cibles tendent vers les performances de l'IMM-MHT. Concernant la complétude du pistage et le ratio de longueur des pistes, elles sont similaires à celles obtenues avec le GM-CPHD, qui est en charge, en quelques sortes, de la détection des objets. Par ailleurs, grâce à la précision de l'estimation du nombre de cibles, même lorsque les cibles sont proches, l'hybridation permet d'améliorer les performances liées aux cibles proches. Nous avons également apporté une contribution concernant la labellisation des pistes issues du GM-CPHD, puisqu'aucune technique spécifique à la modélisation par gaussiennes cardinalisée n'avait alors été proposée. Finalement, dans un souci combinatoire, nous proposons une technique d'optimisation pour la labellisation.

L'algorithme obtenu répond donc bien à la problématique décrite en première partie. Il s'agit d'un algorithme de pistage multicible capable de gérer un grand nombre de cibles qui conserve des performances de pistage aussi bonnes avec les agrégats de véhicules qu'avec les cibles qui sont éloignées les unes des autres, tout en prenant en compte les caractéristiques liées au capteur GMTI : probabilité de détection faible, densité de fausses alarmes élevée, *etc*, comme cela est montré dans les chapitres de résultats (chapitre 7 et 8). Or les capteurs GMTI sont également soumis à de fortes contraintes terrestres (élévations de terrain qui génèrent des zones d'occlusion, présence de route, ...). Il est donc bénéfique d'utiliser l'information contextuelle pour soulager les contraintes et améliorer les performances de l'algorithme hybride proposé.

Il pourrait être intéressant à présent d'aller plus loin dans l'amélioration de cette technique de pistage en introduisant d'autres informations telles que l'information contextuelle (coordonnées des routes, masques de terrain, ...).

Amélioration des performances de pistage

Sommaire

3.1	Introduction des coordonnées des routes pour l'estimation des pistes	94
3.1.1	Projection des cibles sur un segment de route	94
3.1.2	Projection des cibles sur l'ensemble du réseau routier	97
3.1.3	IMM avec contraintes à structure variable	100
3.1.4	Algorithme hybride avec les coordonnées des routes	102
3.2	Introduction du type des cibles	103
3.2.1	Pistage avec le MHT sous contrainte et l'information de type.	103
3.2.2	Pistage avec le GM-CPHD et l'information de type.	105
3.3	Utilisation des masques de terrain	106

Introduction

L'algorithme de pistage multicible hybride, en combinant le filtre GM-CPHD avec un MHT, permet de tirer avantage de l'excellente estimation du nombre de cibles du GM-CPHD et de la bonne estimation en position et vitesse des cibles de l'IMM-MHT. Il a été développé pour prendre en compte la problématique de cibles proches, donc faiblement résolues.

Pour améliorer les performances de pistage, il faut maintenant utiliser des informations supplémentaires. A travers l'étude de la littérature, trois approches pour l'amélioration des performances dans le cadre d'un pistage multicible terrestre sont envisageables. Tout d'abord, l'introduction des coordonnées des routes permet logiquement d'améliorer la précision du pistage dans le cas où les cibles évoluent sur la route (ce qui est vrai la plupart du temps). Ensuite, l'utilisation des informations sur le type des cibles permet d'améliorer la continuité du pistage. Enfin, la prise en compte des masques de terrain (zone cachée par le relief où aucune détection n'est possible) permet de mettre en œuvre des stratégies adaptées aux non-détections successives.

Dans ce chapitre, nous présentons la façon dont nous avons introduit ces informations. Dans la partie 3.1, nous décrivons un algorithme issu du MHT qui utilise les coordonnées des routes dans le processus de pistage. Ensuite, dans la partie 3.1.4, nous décrivons comment cet algorithme est intégré dans l'algorithme hybride que nous avons élaboré. Dans la

partie 3.2, nous nous intéressons à l'utilisation de l'information du type des véhicules. Enfin, dans la partie 3.3, nous présentons la façon dont il serait possible d'utiliser les masques de terrain.

3.1 Introduction des coordonnées des routes pour l'estimation des pistes

La plupart des véhicules, civils ou militaires, se déplacent sur des routes. Ainsi, la connaissance des coordonnées du réseau routier permet d'améliorer la précision du pistage par l'ajout d'une information *a priori*. Nous rappelons donc ici les grands principes de l'algorithme de pistage multicible avec prise en compte des coordonnées routières développé par Benjamin Pannetier durant sa thèse [Pannetier 2006a], connu sous le nom de VS-IMMC-MHT (Variable Structure-Interacting Multiple Model with Constraints - Multiple Hypothesis Tracker).

Un réseau routier est un ensemble de tronçons routiers délimités par des intersections ou des fins de route. Par ailleurs, un tronçon routier est une succession de segments de route, utilisés pour imiter la courbure de leur tracé. Dans cette partie, nous décrivons tout d'abord la mise en œuvre du modèle *On-Road*. En supposant qu'une cible évolue sur la route, nous décrivons tout d'abord comment projeter son état et sa dynamique sur un segment de route (*cf.* Partie 3.1.1), puis sur l'ensemble du réseau routier (*cf.* Partie 3.1.2). Enfin, dans la partie 3.1.3, nous présentons comment les performances de pistage sont améliorées par l'utilisation d'une approche multi-modèle qui prend notamment en compte la possibilité qu'une cible n'évolue pas sur la route (modèle *Off-Road*).

3.1.1 Projection des cibles sur un segment de route

À partir d'un état estimé $\hat{x}_{k,j}^s$ contraint au segment s pour la cible j , on souhaite prédire l'état $\hat{x}_{k|k-1,j}^s$ sur ce même segment s (Partie 3.1.1.1). Par ailleurs, l'état estimé $\hat{x}_{k|k,j}^s$ doit également être projeté (Partie 3.1.1.2).

3.1.1.1 Modèle dynamique contraint

Nous nous plaçons dans le contexte d'un pistage multicible multi-modèle. La dynamique d'une cible est modélisée selon un nombre fini de modèles dynamiques M^l , $\forall l \in \{1, \dots, N^M\}$ où N^M est le nombre de modèles dynamiques envisagés. Dans le cadre du pistage sous contrainte, lorsqu'une cible i évolue selon le modèle M_l^s , cela signifie qu'elle évolue selon le modèle dynamique M_l sur un segment routier s . Le modèle dynamique M_l^s est alors défini selon sa matrice de transition d'état $F_{k,l}^s$ et le vecteur de bruit de modèle $\nu_{k,l}^s$. L'état contraint $x_{k,j}^s$ d'une cible j à l'itération k associé au segment routier s est alors noté :

$$x_{k,j}^s = [x_{k,j}^s, \dot{x}_{k,j}^s, y_{k,j}^s, \dot{y}_{k,j}^s]^T \quad (3.1)$$

avec $(x_{k,j}^s, y_{k,j}^s)$ ses coordonnées position et $\dot{x}_{k,j}^s = (\dot{x}_{k,j}^s, \dot{y}_{k,j}^s)$ ses coordonnées vitesse, toutes deux exprimées dans le repère cartésien local (O, X, Y) .

La nouvelle position $(x_{k,j}^s, y_{k,j}^s)$ a pour contrainte d'appartenir au segment routier s , tandis que la vitesse $\dot{x}_{k,j}^s$ a pour contrainte d'être colinéaire à la droite formée par le segment s . Elle est donc projetée grâce à la matrice de projection P_{\perp}^s telle que :

$$\dot{x}_{k,j}^s = P_{\perp}^s \dot{x}_{k,j} \quad (3.2)$$

La matrice de projection s'obtient en considérant la droite appartenant au segment s d'équation $y = \tan(\theta_s) \cdot x$ telle que $P_{\perp}^s = \mathbf{v} \cdot \mathbf{v}^T$ avec \mathbf{v} un vecteur directeur normalisé de la droite tel que :

$$\mathbf{v} = \frac{1}{\sqrt{1 + \tan^2(\theta)}} \begin{bmatrix} 1 \\ \tan(\theta) \end{bmatrix} \quad (3.3)$$

Finalement, il vient :

$$P_{\perp}^s = \frac{1}{1 + \tan^2 \theta_s} \begin{pmatrix} 1 & \tan \theta_s \\ \tan \theta_s & \tan^2 \theta_s \end{pmatrix} = \begin{pmatrix} P_{\perp 11}^s & P_{\perp 12}^s \\ P_{\perp 21}^s & P_{\perp 22}^s \end{pmatrix} \quad (3.4)$$

où θ_s est l'angle formé par le segment routier s dans le repère cartésien local comme illustré par la figure 3.1.

Ainsi, à partir d'un état estimé $\hat{x}_{k-1,j}^s$ positionné sur le segment s pour la cible j , on souhaite prédire l'état $\hat{x}_{k|k-1,j}^s$ sur ce même segment. L'équation de prédiction à l'itération k devient :

$$\hat{x}_{k|k-1,j}^s = F_{k,l}^s \cdot \hat{x}_{k-1,j}^s \quad (3.5)$$

où $F_{k,l}^s$ est la matrice de transition de l'état selon le modèle dynamique l sous la contrainte du segment s à l'itération k . À partir de l'équation (3.2), elle s'écrit :

$$F_{k,l}^s = \begin{pmatrix} 1 & \Delta P_{\perp 11}^s & 0 & \Delta P_{\perp 12}^s \\ 0 & 1 & 0 & 0 \\ 0 & \Delta P_{\perp 21}^s & 1 & \Delta P_{\perp 22}^s \\ 0 & 0 & 0 & 1 \end{pmatrix} \quad (3.6)$$

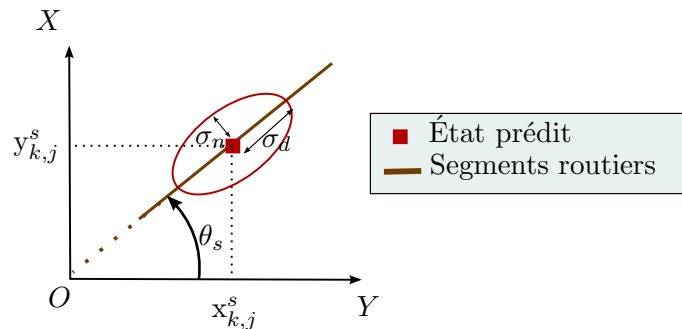


Fig. 3.1 – Orientation de l'écart-type associé au bruit de modèle

Comme la cible est contrainte à rester sur le segment routier s , le bruit de mesure $\nu_{k,l}^s$ est également projeté sur celui-ci. Cependant, le bruit sur le modèle est associé par définition à une légère variation de l'accélération. La composante normale du bruit

d'accélération σ_n ne peut pas être nulle puisque l'accélération n'est pas nécessairement sur la route (cas des virages), cependant elle est beaucoup plus faible par rapport au bruit σ_d dans la direction de la route. C'est pourquoi une rotation de la matrice de covariance $Q_{k,l}^s$ associée aux bruits est effectuée dans le sens de la direction du segment s comme cela est illustré dans la figure 3.1 [Kirubarajan 2000a].

Finalement, la matrice $Q_{k,l}^s$ s'écrit :

$$Q_{k,l}^s = R_{\theta_s} Q_k^s R_{\theta_s}^T \quad (3.7)$$

où R_{θ_s} est la matrice de rotation de l'état dans la direction θ_s engendrée par le segment routier s telle que :

$$R_{\theta_s} = \begin{pmatrix} \cos \theta_s & 0 & \sin \theta_s & 0 \\ 0 & \cos \theta_s & 0 & \sin \theta_s \\ -\sin \theta_s & 0 & \cos \theta_s & 0 \\ 0 & -\sin \theta_s & 0 & \cos \theta_s \end{pmatrix} \quad (3.8)$$

3.1.1.2 Projection optimisée

Dans ces conditions, bien que l'état prédit $\hat{x}_{k|k-1}^{\rightarrow s}$ soit contraint à appartenir au segment s , l'état estimé $\hat{x}_{k|k}$ lui, après mise à jour par l'ensemble des mesures Z_k , n'appartient pas obligatoirement à la route comme cela est illustré par la figure 3.2. Nous utilisons une technique de projection optimisée inspirée des travaux de Simon *et al.* [Simon 2002]. L'estimateur de Kalman décrit en (1.70) devient donc :

$$\hat{x}_{k|k}^{\rightarrow s} = \mathbb{E} [x_k | \mathbf{Z}^k, e_k^s] \quad (3.9)$$

où e_k^s représente l'évènement que la cible x_k évolue sur le segment s à l'itération k . La notation $x^{\rightarrow s}$ désigne la projection de x sur le segment s .

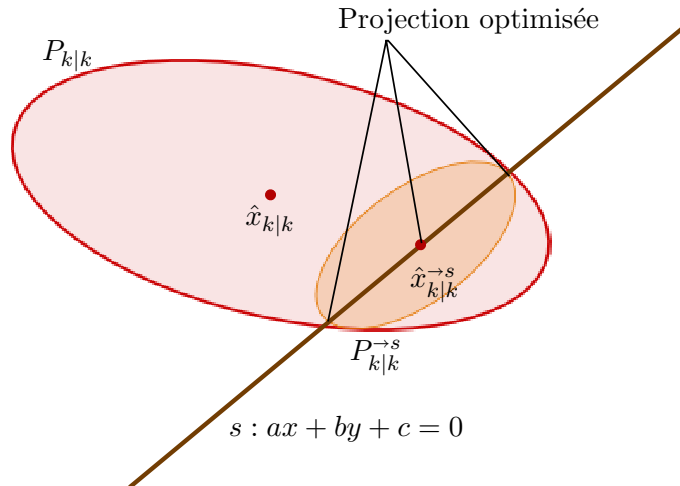


Fig. 3.2 – Projection optimisée de l'état estimé

L'objectif est de trouver un estimateur $\hat{x}_{k|k}^{\rightarrow s}$ qui maximise la probabilité de l'état *a posteriori* des observations conditionnellement à l'évènement e_k^s d'appartenance au segment s à l'itération k .

Il vient :

$$\hat{x}_{k|k}^{\rightarrow s} = \hat{x}_{k|k} - P_{k|k} \cdot \tilde{D}^T \cdot \left(\tilde{D} \cdot P_{k|k} \cdot \tilde{D}^T \right)^{-1} \cdot \left(\tilde{D} \cdot \hat{x}_{k|k} - L \right) \quad (3.10)$$

où \tilde{D} et L expriment la contrainte de projection sur le segment telle que $\tilde{D} = \begin{bmatrix} a & 0 & b & 0 \\ 0 & a & 0 & b \end{bmatrix}$ et $L = \begin{bmatrix} -c \\ 0 \end{bmatrix}$ où la droite engendrée par le segment s dans le repère cartésien local est telle que $ax + by + c = 0$. Plus de détails sur la justification de cette expression sont disponibles en [Pannetier 2006a].

La matrice de covariance associée est obtenue en développant l'espérance quadratique telle que :

$$P_{k|k}^{\rightarrow s} = \mathbb{E} \left[\left(x_k - \hat{x}_{k|k}^{\rightarrow s} \right) \left(x_k - \hat{x}_{k|k}^{\rightarrow s} \right)^T \mid \mathbf{Z}^k \right] \quad (3.11)$$

Soit,

$$P_{k|k}^{\rightarrow s} = (Id - W_k) \cdot P_{k|k} \cdot (Id - W_k)^T \quad (3.12)$$

avec $W_k = P_{k|k} \cdot \tilde{D}^T \cdot \left(\tilde{D} \cdot P_{k|k} \cdot \tilde{D}^T \right) \cdot \tilde{D}$

3.1.2 Projection des cibles sur l'ensemble du réseau routier

Une route est composée de plusieurs segments sur lesquels la cible peut évoluer. Il faut donc déterminer à l'itération k sur quel segment la cible se déplace afin d'adapter la dynamique de la cible et projeter l'état estimé sur ce segment. Par ailleurs, si la projection sur le réseau routier permet de prendre en compte les changements de direction, elle ne permet pas de prendre en compte les manœuvres liées à l'accélération du véhicule. La projection est donc couplée avec plusieurs modèles d'évolution (IMM). Dans ce cadre, nous utilisons une technique réduisant le nombre de modèles dynamiques sous la contrainte de limiter la combinatoire.

Dans un contexte réaliste, une route est composée de plusieurs segments routiers. Il s'agit maintenant d'identifier à l'itération k le segment routier sur lequel évolue la cible afin d'adapter la dynamique de cette dernière au segment puis d'effectuer la projection optimisée.

3.1.2.1 Prédiction

Le principe des transformations successives est illustré par la figure 3.3. À partir de l'estimation $\hat{x}_{k-1|k-1}$, on prédit l'état $\hat{x}_{k|k-1}$ de la cible sur le segment s_0 à l'itération k . À partir du point d'intersection entre s_0 et s_1 , la prédiction $\hat{x}_{k|k-1}$ est projetée sur s_1 . Comme l'état prédit projeté $\hat{x}_{k|k-1}^{\rightarrow s_1}$ n'appartient pas au segment s_1 , il est à nouveau projeté sur s_2 puis s_3 , pour finalement obtenir l'état prédit $\hat{x}_{k|k-1}^{\rightarrow s_3}$ projeté sur s_3 qui appartient bien à s_3 . Il s'agit donc de projeter successivement la cible sur les différents segments parcourus.

{A partir de $\hat{x}_{k-1}^{\rightarrow s_i}$ l'état estimé contraint au segment s_i à l'itération $k - 1$, la position prédite de la cible est calculée en utilisant le modèle dynamique sous contrainte $M_i^{s_i}$ conformément à (1.55). La distance prédite parcourue de la cible $d(\hat{x}_{k-1}^{\rightarrow s_i}, \hat{x}_{k|k-1})$ peut alors être calculée, ainsi que le nombre N^s de segments parcourus lors de cette itération tel que :

$$N^s = \operatorname{argmax}_{\forall N \in \mathbb{N}} \left\{ d(H\hat{x}_{k-1}^{\rightarrow s_i}, \operatorname{int}(s_i, s_{i+1})) + \sum_{n=0}^N \|s_{i+1}\|_2 < d(\hat{x}_{k-1}^{\rightarrow s_i}, \hat{x}_{k|k-1}) \right\} \quad (3.13)$$

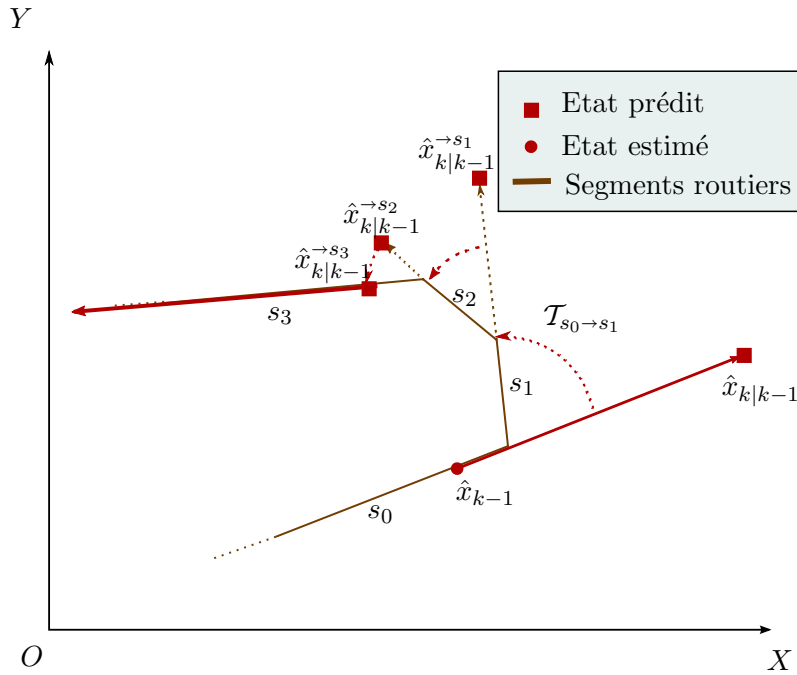


Fig. 3.3 – Étape de prédiction sur un réseau routier - Transformation de la prédiction par rotations successives.

où $\text{int}(s_i, s_{i+1})$ représente le point d'intersection des segments s_i et s_{i+1} et H est la matrice de transformation de l'espace d'état (position-vitesse) vers l'espace des positions comme défini en (1.56). La notation $d(.,.)$ désigne la distance euclidienne entre deux points.

En combinant ces projections, on obtient une nouvelle équation dynamique pour la cible associée au modèle $M_{k,l}^{i+N_s}$:

$$x_k = \mathcal{T}_{s_i \rightarrow s_{i+N_s}} \left(F_{k-1,l}^{s_i} \cdot x_{k-1} \right) + \Gamma_k \cdot \nu_{k-1,l}^{s_{i+N_s}} \quad (3.14)$$

où $\nu_{k-1,l}^{s_{i+N_s}}$ désigne le bruit du modèle l contraint au segment s_{i+N_s} à l'itération k . La transformation $\mathcal{T}_{s_i \rightarrow s_{i+N_s}}$ désigne la combinaison des projections successives permettant de projeter l'état estimé du segment s_i jusqu'au segment s_{i+N_s} telle que :

$$\mathcal{T}_{s_i \rightarrow s_{i+N_s}} = \mathcal{T}_{s_i \rightarrow s_{i+1}} \circ \dots \circ \mathcal{T}_{s_{i+N_s-1} \rightarrow s_{i+N_s}} \quad (3.15)$$

avec $\mathcal{T}_{s_i \rightarrow s_{i+1}}$ la transformation entre deux segments successifs qui s'écrit :

$$\mathcal{T}_{s_i \rightarrow s_{i+1}}(\mathbf{x}) = H^T \text{int}(s_i, s_{i+1}) + R_{\theta_{s_{i+1}} - \theta_{s_i}} (\mathbf{x} - H^T \text{int}(s_i, s_{i+1})) \quad (3.16)$$

L'état prédit contraint est donc obtenu récursivement par N_s transformations successives tel que, $\forall n \in \{1, \dots, N_s\}$:

$$\hat{x}_{k|k-1}^{\rightarrow s_{i+n}} = H^T \text{int}(s_{i+n}, s_{i+n+1}) + R_{\theta_{s_{i+n+1}} - \theta_{s_{i+n}}} \left(\hat{x}_{k|k-1}^{\rightarrow s_{i+n-1}} - H^T \text{int}(s_{i+n}, s_{i+n+1}) \right) \quad (3.17)$$

3.1.2.2 Estimation

À partir de l'état prédit contraint $\hat{x}_{k|k-1}^{\rightarrow s}$ et du jeu de mesure Z^k à l'itération k , l'étape d'estimation peut être réalisée conformément à (1.70). Cependant, même si on considère l'état prédit comme contraint, l'état estimé n'appartient pas, après l'étape d'estimation, au réseau routier. Il faut donc considérer, comme cela est décrit en 3.1.1.2, une technique de projection. La projection de l'état s'effectue généralement sur la droite engendrée par le segment routier associé à la prédiction, sauf si la cible l'a entièrement parcouru. En effet, en raison de la longueur de la longue période d'échantillonnage du capteur GMTI, du bruit sur les mesures, de la densité et de la géométrie du réseau, le risque d'erreur sur le choix du segment routier est important. Par conséquent, l'état estimé peut potentiellement être projeté sur un segment routier autre que celui sur lequel l'état est prédit.

Ainsi, à l'itération k , un ensemble ξ_k de segments routiers sur lequel l'état estimé $\hat{x}_{k|k}$ peut être projeté est déterminé. Comme Kirubarajan dans [Kirubarajan 2000a], l'ensemble des segments routiers qui appartiennent à un certain voisinage de la position prédite est sélectionné (*cf.* Figure 3.4). Le voisinage est évalué à partir d'un test du Chi2 et de la position des extrémités des segments.

Une fois que l'ensemble ξ_k est construit, il faut lever l'ambiguïté et choisir le segment sur lequel évolue la cible. Deux cas sont alors à considérer : celui où tous les segments appartiennent au même tronçon (défini comme une suite de segments) et celui des intersections (entre plus de deux tronçons).

Cas des segments appartenant au même tronçon routier : Lorsque l'ensemble ξ_k contient un ensemble de segments routiers appartenant à un seul et même tronçon, la projection optimisée de l'état est faite sur le segment appartenant à ξ_k qui fournit l'état estimé sous contrainte le plus probable $\hat{x}_{k|k}^{\rightarrow s_{opt}}$. Ainsi, pour trouver le segment routier associé s_{opt} , un test statistique du maximum de probabilité est effectué ([El Najjar 2005]), tel que,

$$s_{opt} = \underset{\forall s \in \xi_k}{\operatorname{argmax}} \mathbb{P} \left\{ x_k = \hat{x}_{k|k}^{\rightarrow s} | Z^k \right\} \quad (3.18)$$

Sous les hypothèses du filtre de Kalman, la densité de probabilité $\mathbb{P} \left\{ x_k = \hat{x}_{k|k}^{\rightarrow s} | Z^k \right\}$ est une distribution gaussienne. Il vient alors :

$$s_{opt} = \underset{\forall s \in \xi_k}{\operatorname{argmax}} \left\{ \frac{1}{\sqrt{2\pi|P_{k|k}|}} \exp \left(-\frac{1}{2} \left(\hat{x}_{k|k}^{\rightarrow s} - \hat{x}_{k|k} \right) (P_{k|k})^{-1} \left(\hat{x}_{k|k}^{\rightarrow s} - \hat{x}_{k|k} \right)^T \right) \right\} \quad (3.19)$$

Cas des intersections : Lorsque la cible s'approche d'une intersection, une ambiguïté apparaît sur le choix du tronçon emprunté par la cible. A cet instant, une mesure n'est pas suffisante pour sélectionner le segment sur lequel évolue la cible. C'est pourquoi une nouvelle stratégie doit être adoptée pour le choix du tronçon (*cf.* Figure 3.5). L'idée est de différer le moment de la décision en utilisant un test séquentiel de Wald [Wald 2004] appelé RSS-SPRT (Road Set Segment based on Sequential Probability Ratio Test) comme cela est décrit dans [Pannetier 2004]. Le problème est illustré




Fig. 3.4 – **Étape d'estimation sur un réseau routier** - Le segment choisi entre s_1 , s_2 et s_3 est celui ayant la plus forte probabilité.

par la figure 3.5. Dans cet exemple, la cible arrive à l'intersection de deux tronçons routiers \mathfrak{T}_2 et \mathfrak{T}_3 . On prédit les états pour chacun des tronçons, donc sur les segments s_3 et s_6 . Chacun des états prédits projetés $\hat{x}_{k|k-1}^{\rightarrow 3}$ et $\hat{x}_{k|k-1}^{\rightarrow 6}$ est mis à jour avec la mesure z_k qui appartient à leur fenêtre de validation. Puis, les états estimés sont projetés sur les segments s_3 et s_6 . Or, à ce stade, il est trop tôt pour décider sur quel tronçon évolue la cible (le test séquentiel de Wald n'est satisfait pour aucune des hypothèses), on conserve donc les deux états estimés projetés $\hat{x}_k^{\rightarrow 3}$ et $\hat{x}_k^{\rightarrow 6}$. À l'itération $k + 1$, l'opération de prédiction projetée est répétée pour les deux hypothèses. On obtient les états prédits $\hat{x}_{k+1|k}^{\rightarrow 5}$ et $\hat{x}_{k+1|k}^{\rightarrow 7}$. Or, la mesure z_{k+1} n'appartient à la fenêtre de validation que de l'état prédit $\hat{x}_{k+1|k}^{\rightarrow 5}$, qui est mis à jour et projeté sur s_5 . Grâce à cette mise à jour, le test séquentiel de Wald est satisfait et la deuxième hypothèse est éliminée : la cible évolue sur le tronçon \mathfrak{T}_2 .

3.1.3 IMM avec contraintes à structure variable

Dans le cadre du pistage multi-modèle, il faut contraindre les différents modèles dynamiques au réseau routier. Ainsi, pour chaque segment routier un IMM est considéré. L'IMM est caractérisé par trois modèles dynamiques : un modèle CV avec bruit de mesure faible, un modèle CV avec bruit de modèle fort et un modèle Stop (*cf.* Figure 3.6). Il est activé si le segment considéré appartient à ξ_k , l'ensemble des segments sur lesquels l'état estimé peut être projeté à l'itération k .

Finalement, l'algorithme VS-IMMC peut se résumer par le synoptique présenté en figure 3.7.

Dans le cadre du pistage multicible, l'approche VS-IMMC pour le pistage d'une cible sur le réseau routier est couplée avec une approche MHT pour gérer les cibles multiples. Dans ce cas, les éventuelles sorties de route des véhicules sont prises en compte [Pannetier 2006b].




Fig. 3.5 – Prise de décision différée dans le cas d'intersection




Fig. 3.6 – Les trois modèles dynamiques génériques - (a) CV bruit de mesure faible
 - (b) CV bruit de modèle fort - (c) Modèle Stop

Ainsi chaque segment routier est associé à un indicateur *off-road*, tel que :

$$Off^s = \begin{cases} 1 & \text{si sortie de route possible} \\ 0 & \text{sinon} \end{cases} \quad (3.20)$$

Contrairement aux approches avec possibilité de sortie de route, l'ensemble de modèles sans contrainte *off-road* peut être désactivé lorsqu'on est sûr que la cible évolue sur la route. Cela permet de s'affranchir de l'augmentation du nombre de scénarios d'association qui peut nuire à la qualité du pistage. En effet, les modèles sans contrainte engendrent des fenêtres de validation volumineuses et non directives par rapport au réseau routier validant ainsi un nombre important et indésirable de mesures. Après avoir regroupé les pistes rattachées à une même cible et mis à jour l'état des pistes, la probabilité de rattacher une piste à un segment routier permet de mesurer conjointement la proximité statistique et la colinéarité du vecteur vitesse entre l'état et un segment routier afin d'activer l'ensemble des modèles dynamiques sous contraintes. Le test séquentiel de Wald, RSS-SPRT, gère automatiquement le cas où plusieurs sous-ensembles sous contraintes sont associés à plusieurs tronçons routiers (cas des intersections).

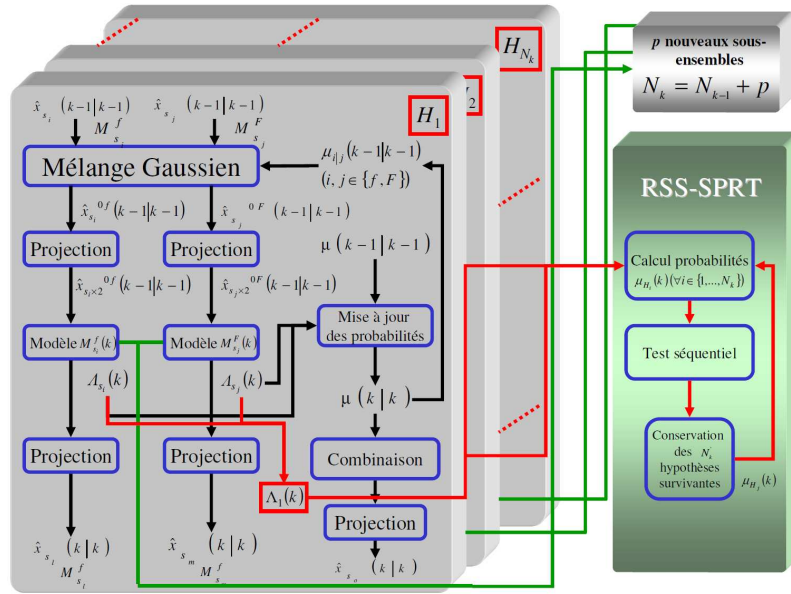


Fig. 3.7 – Synoptique du VS-IMMC pour deux modèles - La flèche verte représente la génération de nouvelles hypothèses liées à l'étape de prédiction. La flèche rouge représente la combinaison des vraisemblances de chaque sous-ensemble de modèle pour l'évaluation de l'hypothèse associée au tronçon.

Lorsque l'ensemble *Off* existe, la probabilité d'appartenance à un segment est calculée. Si la cible n'appartient à aucun segment routier, l'état de la cible est évalué sans contrainte mais l'ensemble des modèles sous contrainte est activé pour le cas où la cible réintégrerait le réseau routier.

3.1.4 Algorithme hybride CPHD et MHT avec prise en compte des coordonnées des routes

Il est intéressant de prendre en compte les coordonnées des routes dans le processus de pistage car cela améliore la précision de l'estimation de l'état des cibles. Ainsi, l'avantage du VS-IMMC rapport à un IMM classique est qu'il apporte une plus grande précision dans l'estimation de l'état des cibles, puisqu'il prend en compte l'infrastructure routière. Après avoir rappelé le fonctionnement de cet algorithme, nous présentons maintenant notre contribution pour la prise en compte du réseau routier. En effet, au vu des travaux présentés dans le chapitre 2, il peut être intéressant de remplacer dans l'hybridation l'IMM-MHT par le VS-IMMC-MHT. L'hybridation ainsi proposée est très similaire à celle proposée précédemment (*cf.* Figure 2.2). Dans le synoptique, le MHT est remplacé par un MHT sous contraintes et les SIG sont ajoutés comme donnée en entrée, afin d'intégrer les coordonnées des segments routiers dans le processus de pistage. De cette façon, on s'attend à ce que les performances de l'algorithme hybride, en terme de précision de l'estimation de l'état, tendent vers les performances du VS-IMMC-MHT, tandis que les performances en terme de précision de l'estimation du nombre de cibles tendent vers celles du filtre GM-CPHD. Ainsi, même si l'introduction des coordonnées routières dans le processus de pistage du GM-CPHD amélioreraient ses performances propres, il est probable qu'elles n'amélioreraient

pas beaucoup les performances de l'hybridation. Cela reviendrait à prendre en compte deux fois la même information. Par conséquent, bien que le GM-CPHD contraint ait déjà fait ses preuves [Ulmke 2007], nous nous limitons ici au GM-CPHD labellisé décrit en 2.4. Finalement, l'hybridation avec contrainte au réseau routier est illustrée par la figure 3.8.

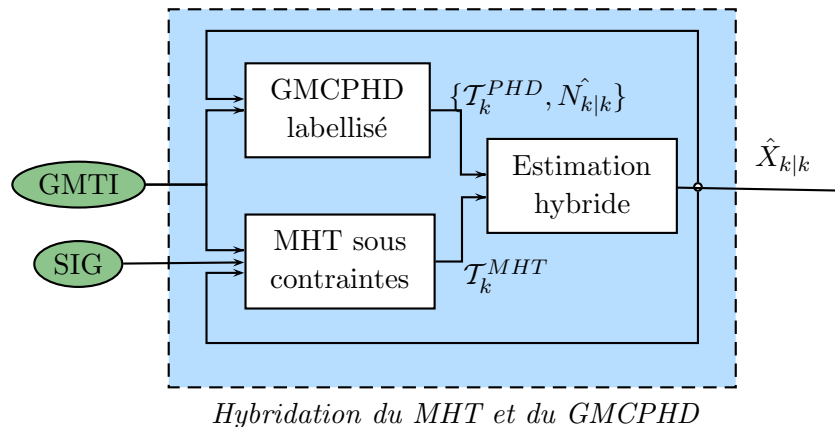


Fig. 3.8 – Hybridation du filtre GM-CPHD et du VS-IMMC-MHT - Synoptique de la labellisation du GM-CPHD présenté en figure 2.5 - Synoptique du VS-IMMC-MHT présenté en figure 3.7

3.2 Introduction du type des cibles

Lorsque l'on dispose d'une information pour le type d'une cible i à l'itération k noté $\mathbf{i}_{k,i}$, tel $\mathbf{i}_{k,i} \in \mathcal{I} = \{\mathbf{i}^a\}_{\forall a \in \{1, \dots, 9\}}$ l'ensemble des 9 attributs \mathbf{i}^a de type présenté en (1.8) (par exemple véhicule à roue, véhicule à chenille, ...), il est possible d'améliorer les performances de pistage, notamment la continuité des pistes. Typiquement, si deux cibles de type différent se croisent (*cf.* Figure 3.9), l'information de type apporte une réelle plus-value lorsque les deux cibles ne sont pas de même type et peut permettre d'éviter des mauvaises associations cible/piste.

Ainsi, nous décrivons dans la sous-partie suivante comment introduire l'information de type dans un MHT, puis comment l'utiliser dans le filtre GM-CPHD, en supposant que le type d'une cible ne change pas au cours du temps.

3.2.1 Pistage avec le MHT sous contrainte et l'information de type.

Dans des travaux présentés à la conférence *Aerospace for Electronic System* (2008), nous avons présenté comment améliorer la continuité du pistage dans le VS-IMMC-MHT, par l'utilisation de l'information de type des cibles [Pannetier 2008].

Avec le MHT, chaque hypothèse d'association mesure/piste est évaluée par le calcul du score $s_{k,l}$ d'une piste l à l'itération k . Celui-ci dépend de la vraisemblance de la i^{me} mesure $z_{k,i}$ associée à la piste l notée $g(z_{k,i}|\mathcal{T}_{k,l})$ comme cela est décrit dans l'équation (2.1). De manière générale, il suffit d'introduire la vraisemblance du type $\mathbf{i}_{k,i}$ associée à la mesure $z_{k,i}$ par rapport au type \mathbf{i}^- associé à la piste l à l'itération précédente noté $\mathbb{P}\{\mathbf{i}_{k,i}|\mathbf{i}^-\}$ tel que :

$$g^{\mathcal{J}}(z_{k,i}|\mathcal{T}_{k,l}) = g(z_{k,i}|\mathcal{T}_{k,l}) \cdot \mathbb{P}\{\mathbf{i}_{k,i}|\mathbf{i}^-\} \quad (3.21)$$




Fig. 3.9 – Illustration des améliorations apportées par le type - (a) Cas du croisement d'un char et d'une voiture - (b) Mauvaise association cible/piste - (c) Bonne association cible/piste

Tout l'enjeu du problème réside à présent dans la façon d'évaluer la probabilité $P\{i_{k,i}|i^-\}$ c'est à dire comment combiner l'information de type $i_{k,i}$ à l'itération k avec le type i^- associé à la piste. Les méthodes de fusion de données fournissent un large panel d'outils (cf. Partie 1.3).

Nous nous sommes intéressés dans cette partie à la théorie crédibiliste et plus particulièrement à la théorie de Dezert-Smarandache (DSmT) [Smarandache 2004]. Ainsi, nous utilisons, pour combiner l'information de type $i_{k,i}$ à l'itération k avec le type associé à la piste i^- à l'itération $k-1$, la règle de redistribution proportionnelle du conflit appelée PCR5 (Proportional Conflict Redistribution rule no 5). Cette règle est utilisée pour le calcul de la masse de croyance sur un des types i^a appartenant à l'ensemble des types considéré \mathcal{J} :

$$m^{PCR5}(i^a) = m_{12}(i^a) + \sum_{i \in \mathcal{J}' \setminus i^a, i^a \cap i = \emptyset} \frac{m_1(i^a)^2 \cdot m_2(i)}{m_1(i^a) + m_2(i)} + \sum_{i \in \mathcal{J}' \setminus i^a, i^a \cap i \neq \emptyset} \frac{m_2(i^a)^2 \cdot m_1(i)}{m_1(i^a) + m_2(i)} \quad (3.22)$$

où \mathcal{J}' représente le cadre de discernement comprenant les unions d'hypothèses ainsi que les intersections d'hypothèses appelé *hyper-set* [Smarandache 2005].

Finalement, le problème du pistage de cible classifiée est résolu par l'utilisation du TTT (Target Type Tracker) [Dezert 2006] dont les différentes étapes sont brièvement résumées ci-dessous :

1. Initialisation des masses de croyances associées à chaque élément de \mathcal{J}' . Il vient $m(i_1 \cup \dots \cup i_9) = 1$.
2. Mesure de la masse de croyance de chaque type i^a , telle que :

$$\tilde{m}(i^a) = C^i(a, a) \quad (3.23)$$

où $C^i(a, a)$ représente les termes diagonaux de la matrice de confusion C^i , connue *a priori* et définie en (1.10). L'ensemble de la masse de croyance qui n'est pas assigné, est transféré sur la masse de l'ignorance $m(i_1 \cup \dots \cup i_9)$.

3. Combinaison de la masse de croyance mesurée $\tilde{m}(i_a)$ avec la masse de croyance à l'itération précédente $m^-(i_a)$ par utilisation de la PCR5. On obtient alors $m^{PCR5}(i_a)$.
4. Transformation des masses de croyances en probabilité en utilisant la transformation pignistique (*cf.* équation (1.54)) pour obtenir la probabilité $P\{i_{k,i}|i^-\}$ du type $i_{k,i}$ de la cible i .
5. Estimation de l'*Id* obtenu en prenant le type qui a la plus forte probabilité pignistique.
6. Récursivement, on écrit $m^-(i_a) = m^{PCR5}(i_a)$ et on retourne à l'étape 2.

Finalement, concernant la mise à jour de la vraisemblance $g^J(z_{k,i}|\mathcal{T}_{k,l})$ d'une mesure $z_{k,i}$ associée à la piste l , le terme $P\{i_{k,i}|i^-\}$ correspond aux probabilités obtenues suite à la transformation pignistique réalisée à l'étape 4 du TTT.

3.2.2 Pistage avec le GM-CPHD et l'information de type.

Comme décrit dans la partie précédente, l'information de type a été intégrée dans le VS-IMMC-MHT par l'utilisation de la DSmT et plus particulièrement de la PCR5. Cependant, nous voulons, à ce stade, attirer l'attention sur deux points. Tout d'abord, le TTT aurait pu intégrer n'importe quelle règle de combinaison d'informations plutôt que la PCR5. Ensuite, le processus d'intégration de l'information de type via la formule (3.21) n'est avantageuse que si une piste n'est associée qu'à une seule mesure. L'introduction du type permet de favoriser certaines associations pistes/mesures qui n'aurait pas été sélectionnées en utilisant seulement le critère spatial lors du calcul de la probabilité d'association. Par exemple, si on regarde l'exemple présenté dans la figure 3.10, on comprend que basé sur le calcul de la probabilité d'association décrit en (1.105), les pistes $\mathbf{T}_{k,1}$ et $\mathbf{T}_{k,2}$ sont associées avec les mesures $z_{k,1}$ et $z_{k,2}$ respectivement. Au regard des types associées aux pistes et mesures, on voit que c'est l'association inverse qui est correcte.

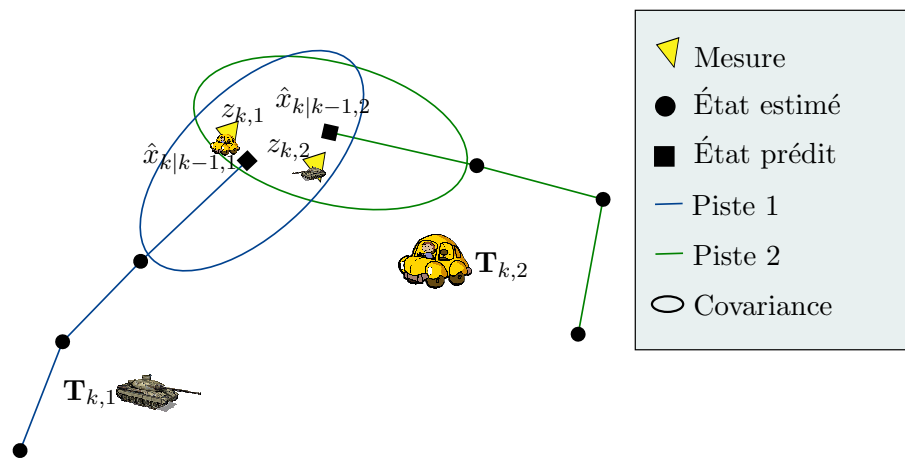


Fig. 3.10 – Scénario problématique d'association

Dans le cadre du filtre CPHD, la vraisemblance $f_k(Z_k|X_k)$ du jeu de mesures Z_k est évaluée par rapport à l'ensemble des cibles X_k , et aucune association cible/mesure n'est

réalisée. Cependant, en pratique, la construction de la fonction d'intensité est faite en considérant des associations gaussiennes/mesures. Nous pouvons donc envisager l'intégration de l'information de type.

Finalement, on obtient :

$$g^{\mathcal{J}}(\mathcal{G}_{k,n}|\hat{x}_{k|k-1,j}) = g(\mathcal{G}_{k,n}|\hat{x}_{k|k-1,j}) \cdot \mathbf{P}\{\mathbf{i}_{k,i}|\mathbf{i}^-\} \quad (3.24)$$

où i est l'indice de la mesure associée à la gaussienne n .

3.3 Utilisation des masques de terrain

Le pistage de cibles terrestres peut être discontinu en raison de l'absence de détection pour une cible, et ce, plusieurs itérations de suite. Ces non-détections peuvent être liées, entre autres, aux masques de terrains. Or, il est possible, en temps réel, de déterminer les zones masquées par le terrain, à partir des modèles numériques de terrain (MNT) et des modèles numériques d'élévation (MNE). Ces zones sont alors perçues comme une information *a priori* utile pour améliorer la continuité du pistage. Ce sont des objets tels que les bâtiments, les arbres ou les montagnes qui obstruent l'axe de visée du capteur (*cf.* Figure 3.11) et qui entraînent la création de zones « d'ombre » ou de non-détection.



Fig. 3.11 – Masque de terrain

L'introduction des masques de terrain dans le VS-IMMC-MHT a été réalisée par Benjamin Pannetier dans [Pannetier 2007]. Dans ses travaux, les masques de terrain sont générées tel que dans les zones d'obscurité la probabilité de détection est nulle ($P_d = 0$). Or, concernant le GM-CPHD, une hypothèse très forte est faite, qui consiste à dire que la probabilité de détection est uniforme sur toute la surface d'observation (*cf.* Partie 2.3.2), telle que,

$$\forall x \in V_k, \quad P_d(x) = P_d \quad (3.25)$$

Cette hypothèse rend incompatible, l'utilisation du filtre GM-CPHD avec les masques de terrain. Or dans le cadre de l'hybridation, pour des raisons d'homogénéité, le pistage

doit être réalisé sur les mêmes cadres de discernement. Par conséquent, l'utilisation des masques de terrain n'est pas envisagée.

Conclusion

Dans ce chapitre, nous avons étudié les différentes possibilités pour l'amélioration des performances de pistage de l'algorithme hybride proposé. Nous avons ainsi introduit, les coordonnées des routes et proposé des solutions dans le cas où le type des cibles est fourni par les données GMTI. Finalement, nous avons écarté pour le moment l'utilisation des masques de terrain dans le processus de pistage.

Les performances obtenues dans le cadre de l'algorithme hybride présenté dans la figure 3.8 sont satisfaisantes et on fait l'objet d'une publication revue [Pollard pear]. Nous sommes ainsi capables de pister un grand nombre de cibles sur une large zone d'observation et les baisses de performances, classiquement observées lorsque les cibles sont proches, sont maintenant limitées. Cela permet de détecter avec précision les agrégats de véhicules. À partir de ces agrégats, nous proposons dans la partie suivante de déterminer si ces derniers sont des convois, en présence de trafic civil ou non.

II

Fusion de données pour la détection d'objets d'intérêt

Un modèle de Réseau Bayésien pour la détection de convoi

Sommaire

4.1	Traitement des agrégats	112
4.1.1	Détection des agrégats	113
4.1.2	Caractéristiques d'un convoi extraites à partir d'un agrégat	114
4.2	Sélection des techniques pour la détection de convois	115
4.2.1	Rappels sur la problématique de détection de convois	116
4.2.2	Choix d'une méthode de représentation du système	116
4.2.3	Choix d'une méthode pour traiter l'information	117
4.3	Modélisation de convois par les réseaux bayésiens	117
4.4	Calcul des probabilités	119
4.4.1	Vitesse inférieure à une vitesse maximum	119
4.4.2	Vitesse constante	122
4.4.3	Critère vitesse	122
4.4.4	Évolution sur la route	123
4.4.5	Véhicules de type militaire	123
4.4.6	Longueur du convoi constante	123
4.4.7	Distance constante entre les cibles	123
4.4.8	Critère distance	124
4.4.9	convoi	124
4.4.10	Bilan	125
4.5	Expertise des probabilités conditionnelles	125
4.5.1	Composition du réseau	125
4.5.2	Établissement des probabilités conditionnelles	126
4.6	Estimation du nombre de cibles	129
4.6.1	Cas où il y a au plus un seul agrégat à chaque itération	129
4.6.2	Cas où il y a plusieurs convois	133

Introduction

Le nouvel algorithme de pistage multicible que nous avons élaboré a pour principal atout de conserver les mêmes performances si les cibles sont proches les unes des autres, contrairement aux approches usuelles. À partir de l'ensemble des pistes $\hat{X}_{k|k}$ de cardinalité $\hat{N}_{k|k}$ de l'algorithme, nous sommes ainsi capables de faire une évaluation globale de la situation, c'est à dire détecter l'ensemble des cibles évoluant sur le théâtre des opérations,

estimer correctement leur nombre, détecter les débuts et fin de pistes, tout en étant robuste aux fausses alarmes et aux non-détections. L'idée est, à présent, d'engager des algorithmes locaux plus puissants en faisant intervenir d'autres capteurs, afin de détecter des objets d'intérêt. Notre étude se focalise à présent sur la détection de convoi, car ce dernier offre de bonnes perspectives de généralisation à d'autres objets d'intérêt.

Grâce à une estimation fiable du nombre de cibles et de leur état, nous pouvons détecter les agrégats de véhicules avec précision. Un agrégat est un ensemble de véhicules proches spatialement à une itération k . Par conséquent, un convoi est un type d'agrégat particulier : il s'agit d'un groupe de véhicules ayant des propriétés physiques, spatiales et cinématiques particulières. À partir des informations spatio-temporelles contenues dans les pistes, ainsi que des informations de type, nous souhaitons déterminer si l'agrégat détecté est un convoi ou non (*cf.* Figure 4.1). La partie détection d'agrégat est assez basique (basée sur un critère de proximité spatiale), tandis que la partie détection de convois est plus complexe, car il faut trouver un moyen adéquat pour gérer d'autres types d'informations (temporelle, type, ...).

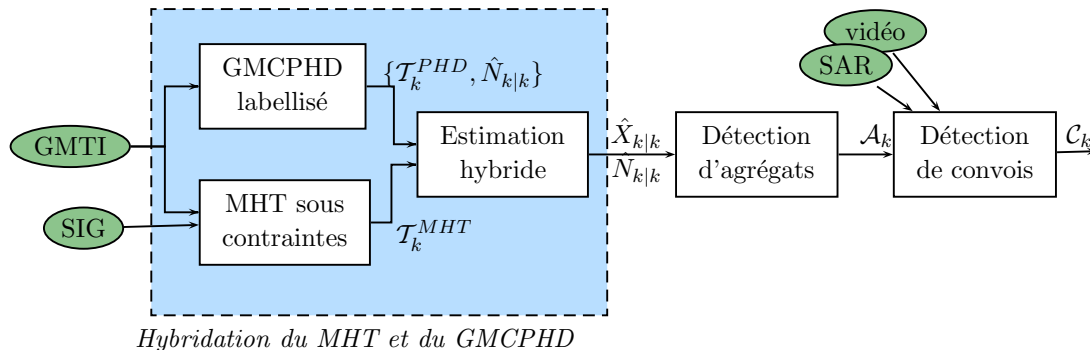


Fig. 4.1 – Processus de détection de convois

La première étape de notre travail (Partie 4.1) consiste donc à détecter les agrégats de véhicules à partir des états estimés des cibles $\hat{X}_{k|k}$ issus de l'algorithme hybride et à les caractériser au mieux (estimation du nombre de cibles, calcul de l'ordre, ...). La deuxième étape (Partie 4.2) consiste à sélectionner une méthode de représentation adaptée pour notre problématique de détection de convois. Il ressort que les réseaux bayésiens offrent un formalisme souple et facile à mettre en œuvre au vu du système à détecter. Cependant, cette mise en œuvre nécessite tout de même quelques explications : la partie 4.4 décrit ainsi la transformation des données en probabilités, tandis que la partie 4.5 propose une solution pour le calcul des probabilités conditionnelles. À partir du modèle graphique de base, nous souhaitons fournir une estimation de l'état du convoi et notamment du nombre de cibles qui le composent (Partie 4.6).

4.1 Traitement des agrégats

Dans cette partie, nous abordons divers aspects concernant le traitement des agrégats. Nous traitons tout d'abord le problème de la détection (Partie 4.1.1), puis la problématique d'extraction des caractéristiques liées à l'agrégat (Partie 4.1.2) et notamment le nombre de cibles qui le composent ainsi que l'ordre dans lequel elles évoluent. Nous présentons

un exemple d'évaluation de la situation en figure 4.2 avec détection d'un agrégat. Ainsi, dans cet exemple, l'algorithme de pistage fournit un ensemble de huit états estimés. Parmi ces huit états estimés, cinq d'entre eux forment un agrégat de $N^A = 5$ cibles caractérisé par son barycentre \hat{x}_k^A et sa covariance P_k^A . Dans l'exemple présenté en figure 4.2, deux




Fig. 4.2 – Exemple d'agrégat

agrégats sont détectés : $\{x_{k,1}, x_{k,2}, x_{k,3}, x_{k,4}\}$ et $\{x_{k,6}, x_{k,7}\}$. La cible 5, elle, n'est proche d'aucune autre. On note que l'opération d'appartenance à l'agrégat est transitive. Si la cible $x_{k,1}$ est proche de la cible $x_{k,2}$ et la cible $x_{k,2}$ est proche de la cible $x_{k,3}$, $x_{k,4}$ et $x_{k,5}$, alors, l'ensemble $\{x_{k,1}, x_{k,2}, x_{k,3}, x_{k,4}, x_{k,5}\}$ forme un agrégat.

4.1.1 Détection des agrégats

Le critère de sélection des cibles appartenant à un agrégat est le critère spatial. Ainsi, la détection d'un agrégat à l'itération k , noté \mathcal{A}_k , est faite grâce à l'étude de la matrice symétrique de proximité des cibles $\mathbf{P}\mathbf{x}$ de taille $(\hat{N}_{k|k} \times \hat{N}_{k|k})$ à l'itération k , qui est remplie de la façon suivante :

$$\mathbf{P}\mathbf{x}(m, n) = \begin{cases} 1 & \text{si } d(x_{k,m}, x_{k,n}) < \alpha^A \\ 0 & \text{sinon} \end{cases} \quad (4.1)$$

avec α^A la distance seuil considérée entre deux cibles pour qu'elles appartiennent à un agrégat. Ainsi, la matrice de proximité correspondant à l'exemple présenté en figure 4.2

s'écrit :

$$\mathbf{P}_x = \begin{bmatrix} 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 1 & 1 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 1 & 1 & 1 & 0 & 0 & 0 \\ 0 & 1 & 1 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 1 \end{bmatrix} \quad (4.2)$$

4.1.2 Caractéristiques d'un convoi extraites à partir d'un agrégat

Un agrégat est ainsi caractérisé par :

une position \hat{x}_k^A : barycentre des différentes positions estimées à l'itération k des cibles le constituant.

une vitesse \hat{x}_k^A : moyenne des vitesses des cibles le constituant.

une covariance P_k^A : somme des covariances des différentes cibles le constituant.

une liste ordonnée des indices des cibles \mathcal{I}^A : indiquant l'ordre dans lequel se suivent les cibles. Dans l'exemple présenté en figure 4.2, la liste est telle que $\mathcal{I}^A = [3, 1, 2, 4, 5]$. Pour calculer cette liste, on considère toutes les combinaisons d'ordonnement possible pour l'ensemble des cibles. Puis la liste est sélectionnée telle que la somme des distances entre les cibles successives soit minimale, comme on le comprend en regardant la figure 4.2.

une longueur \mathcal{L}^A : calculée comme la somme des distances séparant les cibles ordonnée selon la liste \mathcal{I}^A précédemment établie. Sur l'hypothèse que les cibles d'un convoi évoluent sur le réseau routier, nous aurions pu choisir de calculer la longueur du convoi comme la distance parcourue sur le réseau entre le véhicule de tête et le véhicule de queue. Cependant, étant donné que l'état estimé d'une cible n'appartient pas systématiquement au réseau routier, la distance entre deux cibles est calculée comme la distance la plus courte les séparant, indépendamment de la route. Dans l'exemple présenté en figure 4.2, la longueur du convoi est telle que :

$$\mathcal{L}^A = d_{31} + d_{12} + d_{24} + d_{45}$$

une estimation du nombre de cibles $\hat{N}_k^A \in \mathbb{R}^+$: le filtre GM-CPHD fournit une estimation $\hat{N}_{k|k}$ très fiable du nombre de cibles sur la zone d'observation ainsi qu'un nombre fini N^A de cibles dans l'agrégat. Dans le cadre de l'évaluation de cet agrégat, il est intéressant de posséder aussi une estimation \hat{N}_k^A du nombre de cibles dans l'agrégat. Afin de l'obtenir, nous reproduisons le processus de prédiction/estimation (équations (2.15) et (2.25)) du nombre de cibles afin d'obtenir la probabilité $p_{k|k}^A(n), \forall n \in \mathbb{N}$ d'avoir n cibles dans l'aire entourant l'agrégat appelée ZOI réduite (ZOI : Zone Of Interest) comme cela est illustré par la figure 4.3.

L'aire de cette zone est obtenue à partir de la longueur du convoi et une certaine épaisseur $\alpha^{\mathcal{L}}$, définie de manière à contenir l'ellipse de covariance P_k^A de l'agrégat. Finalement, l'aire de la ZOI réduite V_k^A est calculée telle que :

$$V_k^A = (\mathcal{L}^A + \alpha^{\mathcal{L}}) \times \alpha^{\mathcal{L}} \quad (4.3)$$

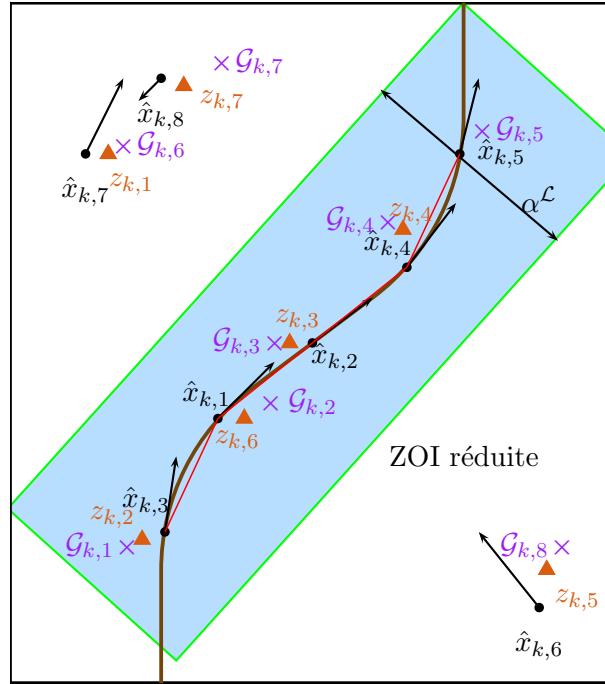


Fig. 4.3 – Positionnement des gaussiennes et des mesures - Pour l'exemple présenté en figure 4.2 - \times position des gaussiennes - \triangle mesure

À partir de ce nouveau volume V_k^A , on peut calculer le nombre moyen de cibles naissantes n_b^A ainsi que le nombre moyen de fausses alarmes n_{fa}^A dans la ZOI réduite, tels que :

$$n_b^A = n_b \cdot \frac{V_k^A}{V_k} \quad (4.4)$$

$$n_{fa}^A = \beta_{fa} \cdot V_k^A \quad (4.5)$$

avec n_b le nombre moyen de cibles naissantes sur toute la zone d'observation.

Puis, en considérant uniquement les gaussiennes appartenant à l'aire V_k^A (pour l'exemple présenté en figure 4.3, on conserve l'ensemble des gaussiennes $\{\mathcal{G}_{k,1}, \dots, \mathcal{G}_{k,5}\}$ avec l'ensemble des mesures associées $\{z_{k,2}, z_{k,3}, z_{k,4}, z_{k,6}\}$). Le nombre de cibles $p_{k|k}^A$ est alors estimé à chaque itération k en appliquant les équations (2.15) et (2.25). Finalement, l'estimation locale est obtenue telle que :

$$\hat{N}_k^A = \sum_{i=1}^{N_{max}} i \cdot p_{k|k}^A(i) \quad (4.6)$$

où N_{max} est le nombre maximal de cibles considéré sur la zone. On le prend égal au nombre maximal de cibles considérées sur toute la zone d'observation car $V_k^A < V_k$.

4.2 Sélection des techniques pour la détection de convois

Après avoir détecté les cibles qui appartiennent à un agrégat, déterminé une zone d'intérêt et caractérisé cet agrégat, l'enjeu est à présent de calculer, à l'itération k , la probabilité que l'agrégat de $N_k^A \in \mathbb{N}^*$ cibles soit un convoi. Le but de cette partie est

donc d'argumenter le choix d'une méthode de détection de convois en se basant sur les techniques usuelles présentées dans la partie 1.5 ainsi qu'une technique de modélisation et de combinaison de l'information (*cf.* Partie 1.3).

4.2.1 Rappels sur la problématique de détection de convois

Les opérationnels définissent un convoi de la manière suivante. *Il s'agit d'un ensemble de véhicules (agrégat) évoluant approximativement selon la même cinématique. Ces véhicules, généralement de type militaire évoluent le plus souvent sur route à une vitesse n'excédant pas 80 km.h⁻¹. En conséquence, la vitesse des véhicules est toujours la même et est constante au cours du temps (sauf en cas d'arrivée à proximité d'un réseau routier urbain). De même, la distance les séparant est toujours la même. Une règle de base pour les véhicules du convoi est qu'ils doivent rester à vue les uns des autres, pour pouvoir stopper le convoi en cas d'incident pour l'un des véhicules. Sur route, par temps clair, la distance les séparant est donc généralement 100m.*

Dans cette définition que nous donnons du convoi, de nombreux mots-clés apparaissent. Une partie de ces mots-clés fait apparaître des caractéristiques physiques (vitesse, type, route, etc.). Certaines informations sont quantitatives ($< 80 \text{ km.h}^{-1}$), d'autres sont qualitatives (constante). Par ailleurs, les termes utilisés dans la définition sont pris dans le sens commun, donc non-scientifique. Ainsi, une vitesse constante ne signifie pas une constance stricte. Il faut également noter que l'on retrouve le vocabulaire de l'incertain (approximativement, environ). Ce dernier est également présent dans la description des données disponibles (*cf.* Parties 1.2.3.2 et 1.2.3.3).

L'enjeu principal est à présent de trouver une représentation qui prennent en compte toutes les caractéristiques du système à détecter ainsi que des capteurs utilisés :

- Données hétérogènes : SAR, MTI, vidéo, SIG.
- Données asynchrones : la période d'échantillonnage du capteur MTI est beaucoup plus courte que pour les capteurs SAR et GMTI.
- Données manquantes : les données SAR, MTI et SIG ne sont pas forcément disponibles.
- Variables aléatoires à valeurs continues (estimation de la position et de la vitesse) et à valeurs discrètes (type).
- Évolution temporelle du système

4.2.2 Choix d'une méthode de représentation du système

De par la multiplicité des critères entrant en interaction pour la détection de convoi, les techniques de type symbolique faisant intervenir la logique binaire ne sont pas bien adaptées (graphes, automates, réseau de Petri). La notion temporelle est également très importante, car on ne souhaite pas détecter un convoi sur une seule itération, mais sur le long terme. Sa période d'action sur un théâtre des opérations est très longue au regard de la période d'échantillonnage du capteur GMTI. Cependant, nous ne sommes pas à la recherche d'une séquence d'évènements conduisant à la détection d'un scénario mais à la recherche d'un ensemble de caractéristiques définissant un objet particulier. Les techniques de type séquentiel (HMM, chroniques) ne sont donc pas non plus adaptées.

Les réseaux bayésiens permettent de modéliser des relations de dépendance entre des variables aléatoires caractérisant un système. De plus, les relations de dépendance

sont quantifiées par l'établissement de probabilités conditionnelles, déterminées soit par expertise soit par apprentissage. L'apprentissage nécessitant l'utilisation de données que nous n'avons pas en nombre suffisant, nous nous contenterons de les déterminer par expertise grâce à la connaissance acquise auprès des opérationnels. La deuxième difficulté réside dans la transformation des observations en probabilités. Dans un cadre plus général, il est également possible de faire de l'apprentissage sur la structure d'un réseau bayésien. À plus long terme, cela pourrait être intéressant pour la détection de nouveaux objet d'intérêt.

4.2.3 Choix d'une méthode pour traiter l'information

Les réseaux bayésiens (ou probabilistes) [Pearl 1988] représentent l'union entre la théorie des graphes et la théorie des probabilités. Ils appartiennent à la classe des « modèles graphiques ». Cependant, bien qu'historiquement la plus connue, l'usage de la théorie des probabilités dans les modèles graphiques n'est pas une obligation. D'autres sortes de modèles graphiques existent avec des modes de propagation de l'information différents telles que les réseaux possibilistes [Gebhardt 1996] et les réseaux de croyances [Xu 1996]. La représentation des connaissances ne se fait alors pas avec des probabilités mais avec des possibilités ou des masses de croyance. Le choix de ces représentations est donc à discuter.

Les réseaux bayésiens sont à présent bien connus et largement utilisés dans le milieu industriel [Weber 2004] aussi bien qu'universitaire [Meviren 2004, Olivier 2003, Hallouli 2004b, Bellot 2002, Donat 2009]. Leur formalisme mathématique puissant ont permis le développement de nombreux outils (apprentissage, arbres de décision, diagramme d'influence, ...). L'implémentation avec formalisme probabiliste paraît donc incontournable.

Par ailleurs, l'aspect temporel est primordial dans notre application. Un convoi est un objet qui a une action sur le long terme. Il faut donc étudier son évolution au cours du temps. Notre modèle graphique de représentation du convoi est donc un **réseau bayésien dynamique**.

4.3 Modélisation de convois par les réseaux bayésiens

La modélisation du système « convoi » fait intervenir de nombreux paramètres. Nous avons sélectionné ainsi les variables aléatoires binaires suivantes :

- vitesse $< 80 \text{ km.h}^{-1}$ pour tous les véhicules,
- constance de la vitesse moyenne du convoi au cours du temps,
- positionnement des véhicules sur la route,
- présence d'un ou plusieurs véhicules de type militaire,
- constance de la longueur du convoi,
- constance de la distance entre les véhicules.

Par l'étude des relations de dépendance entre les variables définies, nous avons abouti au modèle graphique présenté en Figure 4.4. L'objectif est de calculer la probabilité $P\{S_9\}$ pour un agrégat d'être un convoi. Le réseau contient neuf nœuds binaires, dont deux dépendent de leur état à l'itération précédente et cinq peuvent être calculés à chaque itération à partir des états estimés issus du processus de pistage. Les variables aléatoires « Vitesse $< 80 \text{ km.h}^{-1}$ » et « Vitesse constante » aboutissent à une nouvelle variable

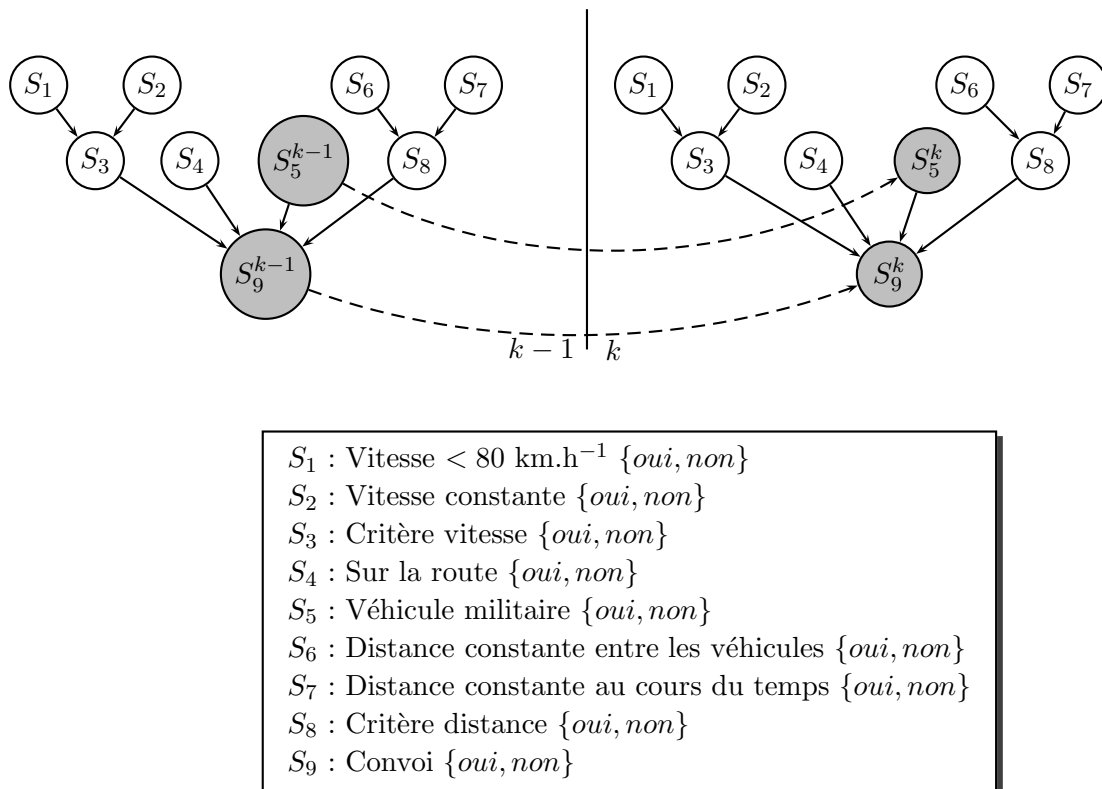


Fig. 4.4 – Modélisation d’un convoi par les réseaux bayésiens - Les nœuds gris représentent les v.a. S_i^k qui dépendent de leur état à l’itération précédente.

nommée « Critère vitesse ». De même pour les variables aléatoires « Distance constante entre les véhicules » et « Distance constante au cours du temps » qui influencent la variable aléatoire « Critère distance ». Finalement, les nœuds « Critère vitesse », « Sur la route », « Véhicule militaire » et « Critère distance », correspondant respectivement aux contraintes cinématique, contextuelle, de type et spatiale aboutissent sur le nœud « Convoi ».

Par ailleurs, l’aspect temporel apparaît clairement dans le réseau, par le fait que deux variables dépendent de leur état à l’instant précédent. Ainsi comme nous l’avons dit, la probabilité d’avoir un convoi à l’itération k (nœud S_9) dépend de la probabilité d’en avoir un à l’itération $k - 1$. Les variations de vitesse et de distance au cours du temps font bien entendu également intervenir le temps, mais les probabilités liées à ces grandeurs ne dépendent pas de l’itération précédente, elles peuvent être calculées à chaque itération. Enfin, concernant l’intégration des données images qui fournissent les données de classification (nœud S_5), si elles interviennent à un instant k , sachant que la période d’échantillonnage des capteurs GMTI est très courte par rapport à la leur, l’information contenue continue à être propagée au cours du temps, au delà d’une seule période d’échantillonnage. Cela nous permet de gérer à la fois les **données manquantes** et les **données asynchrones**.

Un avantage de cette représentation est que les variables d'état, que nous avons définies, sont toutes des variables booléennes ne pouvant donc prendre que deux valeurs : *oui* ou *non*, limitant ainsi le nombre de probabilités conditionnelles à établir. Ainsi, en considérant les 9 variables à l'instant k et les 2 variables dont elles dépendent à l'instant $k - 1$, le calcul de la probabilité que le système soit dans un état s en utilisant la loi jointe serait de complexité $2^{11} = 2048$. Grâce aux réseaux bayésiens, les relations de dépendance entre les variables sont définies et les calculs sont donc limités grâce à la propriété suivante :

$$P \{ S_1, \dots, S_9^{k-1}, S_9^k \} = \sum_{i=1}^{11} P \{ S_i | Pa(S_i) \}$$

où $Pa(S_i)$ représente les noeuds parents de S_i .

À présent, plusieurs spécificités liées aux réseaux bayésiens sont à considérer. Le premier enjeu est de convertir les données en probabilités pour chaque variable (Partie 4.4). Cette opération est souvent désignée sous le terme de **conversion numérique/symbolique**. Puis la manière d'établir les probabilités conditionnelles pour les variables non observées est décrite dans la partie 4.5. Par la suite, nous étendons le problème de détection de convoi à l'évaluation du nombre de cibles contenues dans un convoi dans la partie 4.6.

4.4 Calcul des probabilités

Les variables étant booléennes, pour toute la suite du rapport, la formulation $P \{ S_i \}$ désigne la probabilité que la variable aléatoire soit dans l'état *oui* et la formulation $P \{ \bar{S}_i \}$ désigne la probabilité que la variable aléatoire soit dans l'état *non*.

4.4.1 Calcul de $P \{ S_1 \}$: vitesse inférieure à 80 km.h⁻¹

La variable d'état S_1 représente l'évènement « **Les véhicules du convoi évoluent à une vitesse inférieure à 80 km.h⁻¹** ». Cette probabilité $P \{ S_1 \}$ est calculée comme la moyenne des probabilités $P_i \{ S_1 \}$, pour chacune des cibles i , d'avoir une vitesse inférieure à 80 km.h⁻¹. Cet évènement dépend uniquement des observations à l'instant courant. Pour l'évaluation de cette probabilité $P_i \{ S_1 \}$, la vitesse estimée de la cible i , notée (\hat{x}, \hat{y}) , est utilisée ainsi que la covariance de l'état estimé réduite à la vitesse notée P et telle que :

$$P = \begin{pmatrix} P_{\hat{x}\hat{x}} & P_{\hat{x}\hat{y}} \\ P_{\hat{y}\hat{x}} & P_{\hat{y}\hat{y}} \end{pmatrix} \quad (4.7)$$

On note $\hat{v} = \sqrt{\hat{x}^2 + \hat{y}^2}$ la norme de la vitesse estimée de la cible i à l'itération k . On modélise les variables \hat{x} et \hat{y} comme des lois gaussiennes centrées en leur estimée respective \hat{x} et \hat{y} et de variance $\sigma_{\hat{x}}^2 = P_{\hat{x}\hat{x}}$ et $\sigma_{\hat{y}}^2 = P_{\hat{y}\hat{y}}$. On suppose que $P_{\hat{x}\hat{y}} = P_{\hat{y}\hat{x}} = 0$ et que les variables \hat{x} et \hat{y} ne sont pas corrélées. Leur variance peut être modélisée par le même σ^2 tel que $\sigma = \frac{\sigma_{\hat{x}} + \sigma_{\hat{y}}}{2}$. Les variables \hat{x} et \hat{y} sont donc modélisées telles que :

$$\begin{aligned} \hat{x} &= \mathcal{N} \left(\hat{x}, \sigma^2 \right) \\ \hat{y} &= \mathcal{N} \left(\hat{y}, \sigma^2 \right) \end{aligned} \quad (4.8)$$

Finalement, comme \hat{x} et \hat{y} sont supposées indépendantes, leur densité jointe s'écrit comme le produit des densités de probabilité :

$$f_{\hat{x},\hat{y}}(\hat{x}, \hat{y}) = f_{\hat{x}}(\hat{x}) \cdot f_{\hat{y}}(\hat{y}) \quad (4.9)$$

De manière générale, si \hat{x} et \hat{y} sont deux variables aléatoires modélisées par des lois gaussiennes centrées de variance σ^2 , on obtient :

$$f_{\hat{x},\hat{y}}(\hat{x}, \hat{y}) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{1}{2} \left(\frac{\hat{x}^2 + \hat{y}^2}{\sigma^2}\right)\right) \quad (4.10)$$

La probabilité que la norme $v = \sqrt{\hat{x}^2 + \hat{y}^2}$ soit inférieure à une norme limite v_{max} se calcule comme l'intégrale de la densité de probabilité jointe telle que

$$\mathbb{P}\{v < v_{max}\} = \int_{v \leq v_{max}} \frac{1}{2\pi\sigma^2} \exp\left(-\frac{1}{2} \left(\frac{\hat{x}^2 + \hat{y}^2}{\sigma^2}\right)\right) d\hat{x}d\hat{y} \quad (4.11)$$

On réalise le changement de variables suivant : $\begin{matrix} \hat{x} = a \cdot \cos(b) \\ \hat{y} = a \cdot \sin(b) \end{matrix}$.

La matrice jacobienne associée est notée J telle que :

$$J = \begin{bmatrix} \cos(b) & -a \sin(b) \\ \sin(b) & a \cos(b) \end{bmatrix} \quad (4.12)$$

Il vient alors :

$$\mathbb{P}\{v < v_{max}\} = \int_0^{v_{max}} |J| \frac{1}{2\pi\sigma^2} \cdot \exp\left(-\frac{1}{2} \left(\frac{a^2}{\sigma^2}\right)\right) da \int_0^{2\pi} db \quad (4.13)$$

$$\mathbb{P}\{v < v_{max}\} = \int_0^{v_{max}} \frac{a}{\sigma^2} \cdot \exp\left(-\frac{1}{2} \left(\frac{a^2}{\sigma^2}\right)\right) da \quad (4.14)$$

$$\mathbb{P}\{v < v_{max}\} = \int_0^{v_{max}} f^{Ray}(a, \sigma) da \quad (4.15)$$

où $f^{Ray}(a, \sigma)$ désigne la distribution de probabilité de Rayleigh telle que :

$$f^{Ray}(a, \sigma) = \frac{a}{\sigma^2} \cdot \exp\left(-\frac{1}{2} \left(\frac{a^2}{\sigma^2}\right)\right) \quad (4.16)$$

Dans notre application, la vitesse est centrée autour de la norme de la vitesse estimée $\hat{v} = \sqrt{\hat{x}^2 + \hat{y}^2}$.

La distribution de probabilité de Rayleigh associée s'écrit alors :

$$f^{Ray}(a - \hat{v}, \sigma) = \frac{a - \hat{v}}{\sigma^2} \cdot \exp\left(-\frac{1}{2} \left(\frac{(a - \hat{v})^2}{\sigma^2}\right)\right) \quad (4.17)$$

L'intégration de cette densité de probabilité sur un intervalle où elle est définie positive fournit la probabilité que la vitesse v soit inférieure à v_{max} . Deux cas sont alors à envisager : $\hat{v} < v_{max}$ et $\hat{v} > v_{max}$ comme illustré par la figure 4.5.




Fig. 4.5 – Probabilité que v soit inférieure/supérieure à v_{max} - (a) $\hat{v} < v_{max}$ - (b) $\hat{v} > v_{max}$

- Si $\hat{v} < v_{max}$, alors la probabilité que la vitesse v soit inférieure à v_{max} se calcule telle que :

$$\mathbb{P}\{v < v_{max}\} = 1 - \mathbb{P}\{v > v_{max}\} \quad (4.18)$$

Comme la densité de probabilité $f^{Ray}(a - \hat{v}, \sigma)$ est définie positive sur l'intervalle $[v_{max}, +\infty]$, on peut écrire :

$$\mathbb{P}\{v < v_{max}\} = 1 - \int_{v_{max}}^{+\infty} \frac{a - \hat{v}}{\sigma^2} \exp\left(-\frac{(a - \hat{v})^2}{2\sigma^2}\right) da \quad (4.19)$$

On réalise alors le changement de variable suivant : $u = a - \hat{v}$ tel que

$$\mathbb{P}\{v < v_{max}\} = 1 - \int_{v_{max} - \hat{v}}^{+\infty} \frac{u}{\sigma^2} \exp\left(-\frac{u^2}{2\sigma^2}\right) du \quad (4.20)$$

$$\mathbb{P}\{v < v_{max}\} = 1 - \left[-\exp\left(\frac{-u^2}{2\sigma^2}\right)\right]_{v_{max} - \hat{v}}^{+\infty} \quad (4.21)$$

$$\mathbb{P}\{v < v_{max}\} = 1 - \exp\left(\frac{-(v_{max} - \hat{v})^2}{2\sigma^2}\right) \quad (4.22)$$

- Si $\hat{v} > v_{max}$, alors la probabilité $\mathbb{P}\{v < v_{max}\}$ correspond à l'intégrale de la distribution de Rayleigh où $f^{Ray}(a - \hat{v}, \sigma)$ est négative. Or, par symétrie, cette intégrale correspond à l'intégrale sur l'intervalle $[\hat{v} + (\hat{v} - v_{max}), +\infty]$ où la distribution de Rayleigh est définie positive. Par conséquent, on peut écrire :

$$\mathbb{P}\{v < v_{max}\} = \int_{\hat{v} + (\hat{v} - v_{max})}^{+\infty} \frac{a - \hat{v}}{\sigma^2} \cdot \exp\left(-\frac{1}{2} \left(\frac{a - \hat{v}}{\sigma}\right)^2\right) da \quad (4.23)$$

On réalise le changement de variable suivant : $u = a - \hat{v}$ tel que

$$\mathbb{P}\{v < v_{max}\} = \int_{\hat{v} - v_{max}}^{+\infty} \frac{u}{\sigma^2} \exp\left(\frac{-u^2}{2\sigma^2}\right) du \quad (4.24)$$

$$P\{v < v_{max}\} = \left[-\exp\left(\frac{-u^2}{2\sigma^2}\right) \right]_{\hat{v}-v_{max}}^{+\infty} \quad (4.25)$$

$$P\{v < v_{max}\} = \exp\left(\frac{-(\hat{v} - v_{max})^2}{2\sigma^2}\right) \quad (4.26)$$

4.4.2 Calcul de $P\{S_2\}$: vitesse constante

La variable d'état S_2 représente l'évènement « **Les véhicules du convoi évoluent avec une vitesse constante au cours du temps** » et elle est également booléenne. Nous considérons ici les variations Δv_{moy}^A sur la vitesse moyenne des cibles appartenant à l'agrégat d'une itération sur l'autre. Étant donné que nos données sont incertaines, il est réducteur de trancher brusquement : « si la vitesse moyenne a varié de plus de n m/s, alors la probabilité que S_2 soit dans l'état *oui* est égale à 0 » et inversement. Nous nous basons donc sur un graphe de logique floue (cf. Figure 4.6) pour atténuer l'incertitude de nos mesures en faisant diminuer linéairement la probabilité dès que la variation de vitesse est supérieure à Δ_2 avec un coefficient directeur α_2 . En effet, les limites de passage d'un état à l'autre ne sont pas forcément très nettes, d'où l'utilisation des sous-ensembles flous présentés dans la Figure 4.6. Cependant, cette représentation fait intervenir deux nouvelles variables : α_2 et Δ_2 , réglées selon la confiance accordée aux données. La manière de calculer ces coefficients est présentée dans la partie 7.1.6.




Fig. 4.6 – Variations de la probabilité de S_2

4.4.3 Calcul de $P\{S_3\}$: critère vitesse

La variable S_3 dépend des variables S_1 et S_2 . Il s'agit de savoir si l'agrégat a une vitesse conforme aux caractéristiques d'un convoi. Il vient donc :

$$P\{S_3\} = \frac{1}{2} \cdot (P\{S_3|S_1, S_2\} \cdot P\{S_1\} \cdot P\{S_2\} + P\{S_3|S_1, \bar{S}_2\} \cdot P\{S_1\} \cdot P\{\bar{S}_2\} + P\{S_3|\bar{S}_1, S_2\} \cdot P\{\bar{S}_1\} \cdot P\{S_2\} + P\{S_3|\bar{S}_1, \bar{S}_2\} \cdot P\{\bar{S}_1\} \cdot P\{\bar{S}_2\}) \quad (4.27)$$

où l'ensemble $P\{S_3|\cdot\}$ est l'ensemble des probabilités conditionnelles détaillé dans la partie 4.5.2.

4.4.4 Calcul de $P\{S_4\}$: évolution sur la route

La variable S_4 représente l'évènement « **les véhicules évoluent sur la route** » . Dans l'algorithme VS-IMMC, il est possible de calculer pour chaque piste la probabilité que cette dernière appartienne au réseau routier. En effet, à chaque période d'échantillonnage, il est supposé que la cible puisse quitter le réseau routier (sortie de route, route non cartographiée, ...). Le calcul de cette probabilité est donc fonction de la distance statistique entre l'état prédit contraint au réseau avec la mesure fournie par le capteur (approche usuelle) mais aussi de la vitesse de déplacement du véhicule sur le réseau (si un véhicule se déplace rapidement, ce dernier n'est pas en mesure de changer de direction). Le détail du calcul de cette probabilité est donné dans [Pannetier 2006a].

4.4.5 Calcul de $P\{S_5\}$: véhicules de type militaire

La variable aléatoire S_5 représente l'évènement « **Il y a au moins un véhicule de type militaire dans l'agrégat** » . Cette information nous étant fournie par des images (SAR ou vidéo), la probabilité dépend directement de la confiance accordée à ces sources. Celle-ci dépend par exemple de la résolution des images et des algorithmes d'identification pour les informations image. Nous considérerons donc que l'information sera directement fournie sous la forme d'une probabilité.

4.4.6 Calcul de $P\{S_6\}$: distance constante entre les cibles

La variable aléatoire S_6 représente l'évènement « **La distance entre les différentes cibles du convoi est la même** » . Soit $d_{i,j} = d(x_{k,i}, x_{k,j})$ la distance séparant les véhicules i et j . La probabilité que l'évènement S_6 soit vrai dépend de la variance V_d dans la distribution des distances séparant les véhicules calculée comme suit :

$$V_d = \frac{1}{N^A - 2} \sum_{i=2}^{N^A} d_{i-1,i}^2 - \overline{d_{i,j}}^2 \quad (4.28)$$

avec $\overline{d_{i,j}}$ la moyenne des distances.

Ensuite, la probabilité que la variable S_6 soit dans l'état *oui* suit une loi exponentielle telle que :

$$P\{S_6\} = \exp\left(-\frac{V_d^2}{\sigma_6^2}\right) \quad (4.29)$$

où la manière d'établir la variable σ_6 est décrite dans la partie 7.1.6.

4.4.7 Calcul de $P\{S_7\}$: longueur du convoi constante

La variable aléatoire S_7 représente l'évènement « **la distance entre les différentes cibles du convoi est constante au cours du temps** » . Pour cette variable, nous nous intéressons à la moyenne $\Delta\mathcal{L}^A$ des variations de la distance \mathcal{L}^A entre le véhicule de tête de l'agrégat et le véhicule de queue (longueur de l'agrégat) sur une période d'échantillonnage. La probabilité est ensuite calculée selon la transformation floue décrite dans la figure 4.7 à l'aide des variables α_7 et Δ_7 . La manière de calculer ces coefficients est présentée dans la partie 7.1.6.




Fig. 4.7 – Variations de la probabilité de S_7

4.4.8 Calcul de $P\{S_8\}$: critère distance

De la même façon que pour le critère S_3 , il s'agit de la variable décrivant l'état : « **le critère de distance pour un convoi est rempli.** » Il dépend directement des variables aléatoires S_6 et S_7 et se calcule grâce à la formule suivante :

$$P\{S_8\} = \frac{1}{2} \cdot (P\{S_8|S_6, S_7\} \cdot P\{S_6\} \cdot P\{S_7\} + P\{S_8|S_6, \bar{S}_7\} \cdot P\{S_6\} \cdot P\{\bar{S}_7\} + P\{S_8|\bar{S}_6, S_7\} \cdot P\{\bar{S}_6\} \cdot P\{S_7\} + P\{S_8|\bar{S}_6, \bar{S}_7\} \cdot P\{\bar{S}_6\} \cdot P\{\bar{S}_7\}) \quad (4.30)$$

Le calcul de l'ensemble des probabilités conditionnelles $P\{S_8|.,.\}$ est présentées dans la partie 4.5. Leur valeur numérique sont décrites dans le tableau 4.5.

4.4.9 Calcul de $P\{S_9\}$: convoi

La variable S_9^k représente l'évènement : « **l'agrégat est un convoi** ». Son état à l'itération k dépend de l'état de la variable à l'itération $k - 1$ ainsi que des variables S_3 , S_4 , S_5 , S_8 et S_9^{k-1} . Ainsi la probabilité $P\{S_9^k\}$ que la variable S_9^k soit dans l'état *oui* à l'itération k s'écrit :

$$P\{S_9^k\} = \frac{1}{5} \cdot \left(P\{S_9^k|S_3, S_4, S_5, S_8, S_9^{k-1}\} \cdot P\{S_3\} \cdot P\{S_4\} \cdot P\{S_5\} \cdot P\{S_8\} \cdot P\{S_9^{k-1}\} + P\{S_9^k|\bar{S}_3, S_4, S_5, S_8, S_9^{k-1}\} \cdot P\{\bar{S}_3\} \cdot P\{S_4\} \cdot P\{S_5\} \cdot P\{S_8\} \cdot P\{S_9^{k-1}\} + \dots + P\{S_9^k|\bar{S}_3, \bar{S}_4, \bar{S}_5, \bar{S}_8, \bar{S}_9^{k-1}\} \cdot P\{\bar{S}_3\} \cdot P\{\bar{S}_4\} \cdot P\{\bar{S}_5\} \cdot P\{\bar{S}_8\} \cdot P\{\bar{S}_9^{k-1}\} \right) \quad (4.31)$$

L'équation (4.31) fait intervenir la probabilité $P\{S_9^{k-1}\}$ d'avoir un convoi à l'itération précédente. En effet, comme le nœud S_9^k dépend du temps, le nœud S_9^{k-1} est considéré comme un nœud parent au même titre que les nœuds S_3 , S_4 , S_5 , S_8 . Le fait d'utiliser la probabilité $P\{S_9^{k-1}\}$ dans le calcul de $P\{S_9^k\}$ nécessite de réaliser une étape de mise en

correspondance des agrégats entre les itérations $k - 1$ et k . Cette étape est décrite dans la partie 4.6.

4.4.10 Bilan

Nous avons proposé des solutions pour la transformation des données en probabilités basées sur des transformations floues ou l'étude des covariances évaluées par l'algorithme de pistage. Cependant, dans le cas des transformations floues, un certain nombre de paramètres pour les transformations sont à établir. La question est de savoir si le choix de ces paramètres est critique ou si un raisonnement logique permet de les établir facilement. Il s'avère qu'en réalité ces paramètres peuvent être facilement établis et que l'algorithme de détection de convoi fonctionne avec une gamme large de paramètres. Cela sera montré dans le chapitre 7 de simulation. Le tableau 4.1 liste les différents paramètres à établir.

Notation	Nom
(Δ_2, α_2)	Paramètres du graphe flou de la variable S_2
(Δ_7, α_7)	Paramètres du graphe flou de la variable S_7
σ_6	Paramètre du graphe flou de la variable S_6
α^A	Distance minimale entre deux cibles pour être un agrégat
$\alpha^{\mathcal{L}}$	Épaisseur de la zone d'intérêt
v_{max}	Vitesse maximale autorisée pour un convoi

Tab. 4.1 – Récapitulatif des paramètres pour la mise en œuvre des réseaux bayésiens

4.5 Expertise des probabilités conditionnelles

Après la mise en place de la structure du réseau bayésien (quelles variables aléatoires ? quelles relations de dépendance ?), la deuxième étape clé de notre modélisation est le calcul des probabilités conditionnelles, qui servent à quantifier les relations de dépendance entre les variables. Après avoir établi la composition du réseau, nous présentons une méthode basée sur des heuristiques pour représenter numériquement l'influence des variables parents sur les variables enfants.

4.5.1 Composition du réseau

Afin de mieux comprendre le problème, nous avons décrit le réseau plus précisément dans la Figure 4.8. Les probabilités directement extraites des données ou calculées à partir des données (*cf.* Partie 4.4) sont symbolisées par la couleur verte. Pour ces nœuds, deux probabilités sont à calculer correspondant aux deux états $\{oui, non\}$: le nombre de cases représente donc le nombre d'états possibles. La manière de calculer ces probabilités à partir des données a été présentée dans la partie 4.4. Les probabilités conditionnelles à établir sont elles, décrites en orange. À titre d'exemple, les probabilités conditionnelles liées à la variable S_3 sont au nombre de huit, car il y a 2^3 combinaisons d'états pour S_1, S_2 et S_3 .

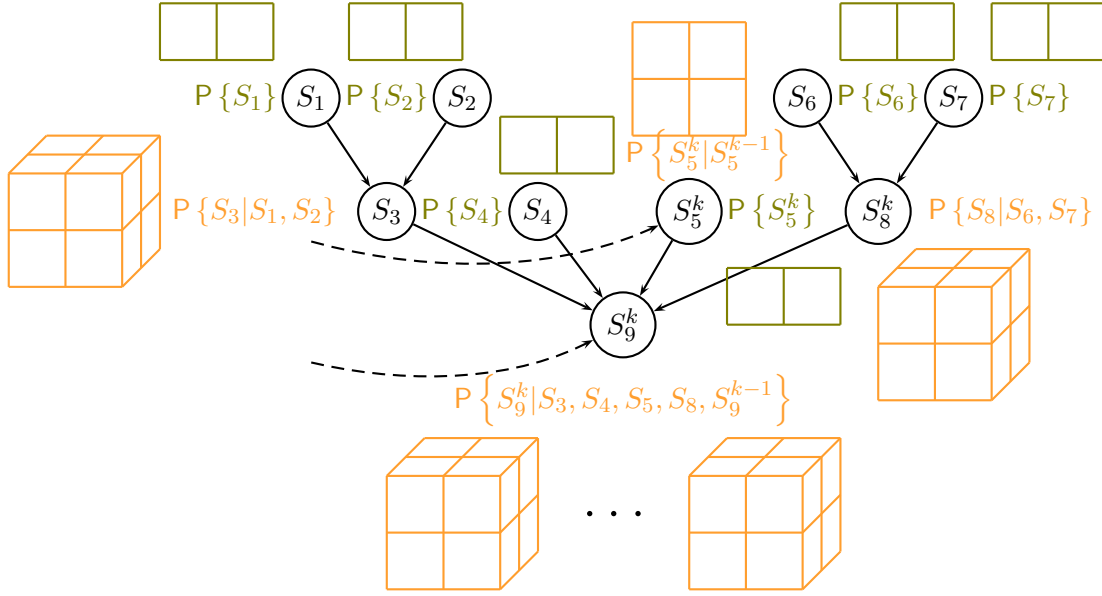


Fig. 4.8 – Décomposabilité du réseau

4.5.2 Établissement des probabilités conditionnelles

Si les relations de dépendance entre les variables peuvent être intuitivement établies dans les réseaux bayésiens, l'une des difficultés avec ce type de méthode consiste à établir de façon fiable les probabilités conditionnelles de chaque nœud connaissant ses parents. Si des jeux de données étaient disponibles, un apprentissage sur ces paramètres aurait été envisageable. Dans notre application, aucune donnée réelle d'apprentissage n'est disponible et les données sont simulées. Par conséquent, un apprentissage n'est pas adapté et ces probabilités doivent être déterminées de façon experte. Nous les établissons donc de façon à pondérer l'influence de l'ensemble des nœuds parents les uns par rapport aux autres. De la même façon que Benavoli dans [Benavoli 2007], nous établissons empiriquement les relations entre les variables et en déduisons les tables de probabilités conditionnelles.

Probabilités conditionnelles concernant la variable S_9^k : Les probabilités conditionnelles de la variable S_9^k dépendent des variables S_3 , S_4 , S_5 , S_8 et S_9^{k-1} . Comme chaque état est binaire, nous devons établir $2^6 = 64$ probabilités conditionnelles correspondant aux différents états du système. Afin de faciliter ce travail, la probabilité que l'état de S_9^k soit *oui* est établie par les relations suivantes :

- Si S_9^{k-1} est dans l'état *oui* :

$$S_9^k \propto 0.5 \times S_9^{k-1} + 0.15 \times S_3 + 0.1 \times S_4 + 0.1 \times S_5 + 0.15 \times S_8 \quad (4.32)$$

S'il y avait un convoi à l'itération précédente, alors la probabilité qu'il y en ait un à l'itération courante est au moins de 0.5. Le signe \propto définit ici les poids accordés à chaque variable. La somme des poids est égale à 1.

- Si S_9^{k-1} est dans l'état *non* :

$$S_9^k \propto 0.3 \times S_3 + 0.2 \times S_4 + 0.2 \times S_5 + 0.3 \times S_8 \quad (4.33)$$

S'il n'y avait pas de convoi à l'itération précédente, alors la probabilité qu'il y en ait un à l'itération courante dépend uniquement des variables S_3 , S_4 , S_5 et S_8 . Les relations précédentes sont exprimées sous la forme du tableau 4.2 de probabilités conditionnelles.

$S_9^{k-1} S_3 S_4 S_5 S_8$	$P \{S_9^k\}$	$P \{\bar{S}_9^k\}$
o o o o o	0.99	0.01
o o o o n	0.85	0.15
o o o n o	0.9	0.1
o o n o o	0.9	0.1
o n o o o	0.85	0.2
o n n o o	0.75	0.25
o n o o n	0.7	0.3
o n o n o	0.75	0.25
o o n n o	0.8	0.2
o o n o n	0.75	0.25
o o o n n	0.75	0.25
o n n n o	0.65	0.35
o n n o n	0.6	0.4
o n o n n	0.6	0.4
o o n n n	0.65	0.35
o n n n n	0.5	0.5
n o o o o	0.99	0.5
n o n o o	0.8	0.2
n o o n o	0.8	0.2
n n o o o	0.7	0.3
n o o o n	0.7	0.3
n o n n o	0.6	0.4
n n n o o	0.5	0.5
n n o n o	0.5	0.5
n o n o n	0.5	0.5
n o o n n	0.5	0.5
n n o o n	0.4	0.6
n n n n o	0.3	0.7
n n n o n	0.2	0.8
n n o n n	0.2	0.8
n o n n n	0.2	0.8
n n n n n	0.01	0.99

Tab. 4.2 – Tableau des probabilités conditionnelles de S_9

En reprenant ligne par ligne ce tableau, on retrouve bien les relations exprimées précédemment. Ainsi,

- si tous les nœuds S_9^{k-1} , S_3 , S_4 , S_5 et S_8 sont dans l'état *oui*, alors, la probabilité que S_9^k soit dans l'état *oui* est de 0.99,
- si tous les nœuds S_3 , S_4 , S_5 et S_8 sont dans l'état *oui*, mais qu'il n'y avait pas de convoi à l'itération précédente ($P \{S_9^k\} = 0$), alors la probabilité que S_9^k soit dans

l'état *oui* est de 0.5,

- si les nœuds S_9^{k-1} , S_4 , S_5 et S_8 sont dans l'état *oui* et S_3 est dans l'état *non*, alors, la probabilité que S_9^k soit dans l'état *oui* est de 0.85, car le nœud S_3 est pondéré par 0.15 selon (4.32).

Ainsi les valeurs du tableau 4.2 traduisent le fait que s'il y a un convoi à l'instant $k - 1$, alors il est probable qu'il y en ait un à l'instant k , et simultanément s'il n'y a pas de convoi à l'instant $k - 1$, rien n'indique qu'il n'y en aura pas un à l'instant k (*i.e.* les évènements sont équiprobables : $P\{S_9\} = P\{\bar{S}_9\} = 0.5$).

Probabilités conditionnelles concernant la variable S_3 : La probabilité que l'état de S_3 soit *oui* est établie par la relation suivante liée aux variables $\{S_1, S_2\}$:

$$S_3 \propto 0.5 \times S_1 + 0.5 \times S_2 \quad (4.34)$$

Tandis que la probabilité que l'état de S_3 soit *non* donne :

$$\bar{S}_3 \propto 0.5 \times \bar{S}_1 + 0.5 \times \bar{S}_2 \quad (4.35)$$

	$S_1 = o$ $S_2 = o$	$S_1 = o$ $S_2 = n$	$S_1 = n$ $S_2 = o$	$S_1 = n$ $S_2 = n$
$S_3 = o$	0.99	0.5	0.5	0.01
$S_3 = n$	0.01	0.5	0.5	0.99

Tab. 4.3 – Tableau des probabilités conditionnelles de S_3

Nous aurions pu imaginer un cas de figure où la variable S_1 aurait eu plus d'influence que la variable S_2 sur le nœud S_3 . On peut défendre l'idée que la plupart des véhicules évoluent sur route à une vitesse supérieure à 80 km.h⁻¹, donc ce critère est plus important que la constance. Nous aurions ainsi établi la relation :

$$S_3 \propto 0.7 \times S_1 + 0.3 \times S_2 \quad (4.36)$$

Nous aurions alors obtenu la table conditionnelle 4.4.

	$S_1 = o$ $S_2 = o$	$S_1 = o$ $S_2 = n$	$S_1 = n$ $S_2 = o$	$S_1 = n$ $S_2 = n$
$S_3 = o$	0.99	0.7	0.3	0.01
$S_3 = n$	0.01	0.3	0.7	0.99

Tab. 4.4 – Tableau des probabilités conditionnelles de S_3 Une autre table

Probabilités conditionnelles concernant la variable S_8 : La probabilité que l'état de S_8 soit *oui* est établie par la relation suivante liées aux variables $\{S_6, S_7\}$:

$$S_8 \propto 0.5 \times S_6 + 0.5 \times S_7 \quad (4.37)$$

Tandis que la probabilité que l'état de S_8 soit *non* donne :

$$\bar{S}_8 \propto 0.5 \times \bar{S}_6 + 0.5 \times \bar{S}_7 \quad (4.38)$$

Ainsi, pour les tables de probabilités liées aux variables S_3 et S_8 , un poids similaire est accordé aux variables parents $\{S_1, S_2\}$ et $\{S_6, S_7\}$ que l'état soit *oui* ou *non*.

	$S_6 = o$	$S_6 = n$	$S_7 = o$	$S_7 = n$
$S_8 = o$	0.99	0.5	0.5	0.01
$S_8 = n$	0.01	0.5	0.5	0.99

Tab. 4.5 – Tableau des probabilités conditionnelles de S_8

Probabilités conditionnelles concernant la variable S_5 : Quand on reçoit une information sur le type des véhicules composant l’agrégat, l’état de $P\{S_5\}$ devient égal à 0 ou à 1. En l’absence d’information, la valeur de $P\{S_5^k\}$ doit tendre vers 0.5 au cours du temps afin de traduire le fait qu’au bout d’un certain temps, la valeur de $P\{S_5^k\}$ est inconnu, ce qui se traduit en probabilité par $P\{S_5^k\} = P\{\bar{S}_5^k\} = 0.5$.

	$S_5^{k-1} == o$	$S_5^{k-1} == n$
$S_5^k == o$	0.9	0.1
$S_5^k == n$	0.1	0.9

Tab. 4.6 – Tableau des probabilités conditionnelles de S_5

La vitesse de décroissance de la probabilité $P\{S_5^k\}$ dépend du paramètre $P\{S_5^k|S_5^{k-1}\}$ (ici 0.9). Plus ce paramètre est proche de 1 plus la vitesse de décroissance est lente.

Une autre possibilité ici aurait été d’établir arbitrairement qu’en l’absence d’information, $P\{S_5\}$ suit une loi exponentielle décroissante du type $P\{S_5\} = \frac{1}{2}exp(-\alpha t) + 0.5$ connu également sous le nom de processus d’oubli ou de *fading* qui tend également vers 0.5.

4.6 Estimation du nombre de cibles

4.6.1 Cas où il y a au plus un seul agrégat à chaque itération

Soit \mathcal{A}_k l’agrégat détecté à l’itération k caractérisé par son état \hat{x}_k^A , sa covariance P_k^A et son nombre de cibles N^{A_k} . Sa probabilité d’être un convoi est notée $P\{S_9^k|N^{A_k}\}$.

À l’itération $k + 1$, un agrégat \mathcal{A}' (de barycentre \hat{x}' , de covariance P' et de cardinalité $N^{A'+\infty}$) est détecté. On souhaite vérifier s’il peut être mis en correspondance avec l’agrégat \mathcal{A}_k . On prédit alors la position de \mathcal{A}_k à l’itération $k + 1$ notée $\hat{x}_{k+1|k}^A$ à l’itération $k + 1$ ainsi que sa covariance $\hat{P}_{k+1|k}^A$, telle que :

$$\hat{x}_{k+1|k}^A = F\hat{x}_k^A \tag{4.39}$$

et

$$\hat{P}_{k+1|k}^A = FP_k^A F^T + Q^A \tag{4.40}$$

où F est le modèle de transition de l’état du convoi choisi semblable au modèle de mouvement d’une cible décrit en (1.58) et Q^A définit l’incertitude sur le modèle utilisé comme défini en (1.60).

À partir de la position prédite $\hat{x}_{k+1|k}^A$ de l'agrégat précédent et de la matrice de covariance associée $\hat{P}_{k+1|k}^A$, on réalise un fenêtrage statistique de seuil γ (défini dans la partie 1.4.6.1) pour savoir si l'agrégat \mathcal{A}_k détecté à l'itération k peut être mis en correspondance avec l'agrégat \mathcal{A}' détecté à l'itération $k + 1$, tel que si :

$$\left(\hat{x}_{k+1|k}^A - \hat{x}'\right)^T \left(P_{k|k-1,j}^A\right)^{-1} \left(\hat{x}_{k+1|k}^A - \hat{x}'\right) < \gamma \quad (4.41)$$

alors les agrégats détectés à l'itération k et $k + 1$ peuvent être mis en correspondance et forment donc une séquence d'agrégats $\mathcal{A}_{k:k+1}$. La séquence de cardinalité de ces agrégats est notée $N_{k:k+1}^A$. La probabilité que \mathcal{A}_{k+1} soit un convoi à l'itération k est notée $P\left\{S_9^{k+1}|N_{k:k+1}^A\right\}$. Elle est calculée en utilisant la probabilité d'avoir un convoi à l'itération précédente $P\left\{S_9^k|N^{\mathcal{A}_k}\right\}$. À l'initialisation (si \mathcal{A}_{k+1} est détectée pour la première fois), on utilise $P\left\{S_9^k|N^{\mathcal{A}_k}\right\} = 0.5$.

Par ailleurs, afin d'affiner l'estimation qui est faite du convoi, on souhaite assigner à chaque agrégat un nombre de cibles le composant. Considérons à présent le cas d'une séquence d'agrégats $\mathcal{A}_{k_0:k}$ mis en correspondance entre k_0 et k . La séquence des nombres de cibles les composant est notée $N_{k_0:k}^A$. Cette séquence peut contenir des éléments différents; autrement dit différentes hypothèses pour le nombre réel de cibles composant le convoi. Il est possible qu'à l'itération $k - 1$, un agrégat contenant n cibles soit détecté et qu'à l'itération k , un agrégat contenant $n + 1$ cibles soit mis en correspondance avec lui. Un doute sur le nombre de cibles du convoi potentiel apparaît. La différence peut venir d'une erreur dans l'estimation du nombre réel de cibles par l'algorithme de pistage ou d'une variation dans la cardinalité de l'agrégat dues à des manœuvres (doublement, croisement, séparation de convoi). Par conséquent, on souhaite calculer la probabilité d'avoir un convoi de N^C cibles où N^C désigne le nombre supposé de cibles dans le convoi. Mathématiquement, cela signifie que l'on calcule la probabilité $P\left\{S_9^k|N_{k_0:k}^A, N_i^C\right\}$ d'existence d'un convoi de N_i^C cibles connaissant la séquence du nombre de cibles $N_{k_0:k}^A$ dans la séquence des agrégats mis en correspondance $\mathcal{A}_{k_0:k}$. L'ensemble $\left\{N_i^C\right\}_{\forall i}$ désigne l'ensemble des valeurs différentes prises par la séquence $N_{k_0:k}^A$. La probabilité $P\left\{S_9^k|N_{k_0:k}^A, N_i^C\right\}$ est donc conjointement calculée pour toutes les valeurs de $\left\{N_i^C\right\}_{\forall i}$. Chacune d'elles représente une hypothèse de cardinalité pour un convoi. La gestion de ces hypothèses implique de distinguer plusieurs cas :

- Si à l'itération k , on détecte un agrégat de N' cibles et $N' \notin \left\{N_i^C\right\}_{\forall i}$, on initialise une nouvelle hypothèses de cardinalité.

Ensuite pour une valeur donnée de N_i^C ,

- Si à l'itération k , on détecte un agrégat de N' cibles et $N' \leq N_i^C$, on calcule la probabilité de S_9 en utilisant les N' cibles de l'agrégat.
- Si à l'itération k , on détecte un agrégat de N' cibles et $N' > N_i^C$, on calcule la probabilité de S_9 en sélectionnant N_i^C cibles parmi les N' cibles de l'agrégat. Pour faire cette sélection, on choisit les N_i^C cibles qui sont le mieux disposées spatialement pour constituer un convoi (*i.e.* les cibles dont la variance dans la distribution des distances entre les cibles est la plus faible), comme cela est illustré par la figure 4.9.

Pour bien comprendre les enjeux et les problématiques liées à la gestion des hypothèses pour le nombre de cibles dans un agrégat, nous présentons dans la figure 4.10, les résultats obtenus pour le calcul de $P\left\{S_9^k|N_{k_0:k}^A, N_i^C\right\}$ sur un cas simple avec la vérité terrain (on utilise en entrée la position réelle des cibles et non pas les pistes issues de l'algorithme




Fig. 4.9 – **Choix des N_i^C cibles parmi les N^{A_k} cibles de l'agrégat** - l'ensemble $\{\hat{x}_{k,1}, \dots, \hat{x}_{k,5}\}$ fournit l'ensemble de 5 cibles dont la variance dans la distribution des distances entre les cibles est minimale par rapport à si on sélectionne la cible $\hat{x}_{k,6}$

de pistage) illustré par la figure 4.10. Il s'agit d'un convoi de 6 cibles doublé par une cible supplémentaire entre t_3 et t_4 . Au temps t_0 , on commence la détection de convoi et on détecte un agrégat de 5 cibles (c'est le démarrage : seules 5 cibles parmi les 6 ont démarré), on calcule donc à partir de cet instant la probabilité $P\{S_9^t | N_{t_0:t}^A, N_i^C = 5\}$. Au temps t_1 , le même agrégat est détecté, mais avec 6 cibles, on calcule alors les probabilités $P\{S_9^t | N_{t_1:t}^A, N_i^C = 6\}$ et $P\{S_9^t | N_{t_0:t}^A, N_i^C = 5\}$. Au temps t_2 , la cible supplémentaire est détectée dans l'agrégat, on calcule alors $P\{S_9^t | N_{t_2:t}^A, N_i^C = 7\}$ en plus des probabilités pour $N_i^C = 5$ et $N_i^C = 6$. Au temps t_4 , la cible supplémentaire a fini de doubler le convoi. Au temps t_5 , la cibles supplémentaire n'est plus détectée dans l'agrégat.

Les courbes $P\{S_9^t | N_{t_1:t}^A, N_i^C = 6\}$ et $P\{S_9^k | N_{t_0:t}^A, N_i^C = 5\}$ sont similaires sauf à l'initialisation. En effet, pour calculer la probabilité d'avoir un convoi de 5 cibles, on sélectionne les 5 cibles parmi les 6 cibles de l'agrégat qui ont la meilleure configuration spatiale pour être un convoi. Comme, nous utilisons la vérité terrain, la probabilité d'avoir un convoi de 5 cibles est égale à la probabilité d'avoir un convoi de 6 cibles.

À partir de t_2 , on détecte une 7^{ème} cible qui ne se comporte pas comme les autres cibles du convoi. Au début (entre t_2 et t_3), la probabilité $P\{S_9^t | N_{t_2:t}^A, N_i^C = 7\}$ n'est pas très forte puisque deux des critères, celui de constance de la distance entre les véhicules (S_6) et celui de constance de la longueur du convoi (S_7), ne sont pas vérifiés. Puis, la probabilité d'avoir $N_i^C = 7$ cibles se rapproche pendant la durée du dépassement (entre t_2 et t_3) vers une valeur plus faible que celle d'avoir 6 cibles (0.75), puisque les autres critères ne sont pas aussi bien vérifiés (la cible supplémentaire a une vitesse supérieure à la vitesse limite (S_1), la vitesse n'est pas constante (S_2) et la distance entre les véhicules est variable).




Fig. 4.10 – $P \{S_9^k | N_{k_0:k}^A, N_i^C\}$: probabilité qu’un agrégat soit un convoi sachant N_i^C . N_i^C : nombre supposé de cibles qui composent le convoi

À partir de t_3 , la probabilité chute pour $N_i^C = 7$ cibles. En effet, la cible supplémentaire a fini de doubler le convoi et s’éloigne du convoi, faisant tendre $P \{S_6\}$ vers 0. Une fois que la cible supplémentaire n’est plus détectée dans l’agrégat (en t_5), la probabilité d’avoir un convoi de 7 cibles continue cependant à être calculée et elle converge vers la valeur de la probabilité d’avoir un convoi de 6 cibles, ce qui est normal puisque on utilise les états des 6 cibles du convoi pour mettre à jour la probabilité d’avoir un convoi de 7 cibles.

À travers l’étude de ce cas simple, il apparaît qu’introduire la connaissance du nombre de cibles dans un convoi est intéressant, puisque pendant la phase d’un dépassement, on arrive bien à discriminer les cas 6 et 7 cibles. Néanmoins, on ne discrimine pas bien les cas 5 et 6 cibles pendant toute la simulation et les cas 5, 6 et 7 cibles après la fin du dépassement.

Or, nous disposons d’une information très simple pour discriminer tous ces cas : $N_{t_0:t_{fin}}^A$ la séquence du nombre de cibles dans l’agrégat. Par exemple, pour l’hypothèse où le convoi contient 5 cibles, on détecte 5 cibles dans le convoi uniquement en t_0 . Par conséquent, si nous introduisons la vraisemblance d’avoir 5 cibles dans le convoi sachant la séquence du nombre de cibles $N_{t_0:t_{fin}}^A$, nous allons affaiblir cette probabilité au cours de temps.

Par ailleurs, dans un cas simulé (calcul des probabilités avec les pistes de l’algorithme hybride au lieu de la vérité terrain), des erreurs de labellisation peuvent être commises ; par exemple, on détecte $N^{A_k} = 5$ cibles dans l’agrégat alors qu’il était vraisemblable d’en détecter 6 et l’estimation du nombre de cibles dans l’agrégat fournit \hat{N}_k^A proches de 6 cibles. Afin d’atténuer les erreurs de labellisation, nous introduisons donc également le nombre estimé \hat{N}_k^A de cibles calculé en (4.6).

Finalement, pour obtenir le nombre de cibles contenues dans le convoi le plus probable,

nous calculons :

$$\mathbb{P} \left\{ N_i^C | S_9^k, N_{k_0:k}^A, \hat{N}_k^A \right\} = \frac{\mathbb{P} \left\{ S_9^k | N_i^C, N_{k_0:k}^A, \hat{N}_k^A \right\} \cdot \mathbb{P} \left\{ N_i^C | N_{k_0:k}^A, \hat{N}_k^A \right\}}{\sum_i \mathbb{P} \left\{ N_i^C | S_9^k, N_{k_0:k}^A \right\}} \quad (4.42)$$

Comme la variable S_9^k est indépendante de l'estimation du nombre de cibles dans l'agrégat, on a :

$$\mathbb{P} \left\{ N_i^C | S_9^k, N_{k_0:k}^A, \hat{N}_k^A \right\} = \frac{1}{c} \cdot \mathbb{P} \left\{ S_9^k | N_i^C, N_{k_0:k}^A \right\} \cdot \mathbb{P} \left\{ N_i^C | N_{k_0:k}^A, \hat{N}_k^A \right\} \quad (4.43)$$

où $c = \sum_i \mathbb{P} \left\{ N_i^C | S_9^k, N_{k_0:k}^A \right\}$ désigne la constante de normalisation et la probabilité $\mathbb{P} \left\{ S_9^k | N_i^C, N_{k_0:k}^A \right\}$ est directement évaluée.

Si on suppose que l'estimation du nombre de cibles \hat{N}_k^A est indépendante du nombre de cibles détectées dans l'agrégat par l'algorithme de pistage. Donc :

$$\mathbb{P} \left\{ N_i^C | N_{k_0:k}^A, \hat{N}_k^A \right\} = \mathbb{P} \left\{ N_i^C | \hat{N}_k^A \right\} \cdot \mathbb{P} \left\{ N_i^C | N_{k_0:k}^A \right\} \quad (4.44)$$

Finalement, en limitant le calcul de la vraisemblance de N_i^C par rapport au nombre de cibles détectées à l'itération courante, il vient :

$$\mathbb{P} \left\{ N_i^C | N_{k_0:k}^A, \hat{N}_k^A \right\} = \mathbb{P} \left\{ N_i^C | \hat{N}_k^A \right\} \cdot \mathbb{P} \left\{ N_i^C | N_{k_0:k}^A \right\} \quad (4.45)$$

La probabilité $\mathbb{P} \left\{ N_i^C | \hat{N}_k^A \right\}$ est calculée comme la vraisemblance gaussienne de variance σ_N telle que :

$$\mathbb{P} \left\{ N_i^C | \hat{N}_k^A \right\} = \frac{1}{\sqrt{2\pi\sigma_N^2}} \exp \left(-\frac{(N_i^C - \hat{N}_k^A)^2}{2\sigma_N^2} \right) \quad (4.46)$$

Les détails concernant le choix du paramètre σ_N sont donnés dans la partie 7.1.6.

La probabilité $\mathbb{P} \left\{ N_i^C | N_{k_0:k}^A \right\}$ est calculée en utilisant une transformation linéaire floue de paramètres (α_N, Δ_N) ayant la même forme que pour la figure 4.6. Les paramètres (α_N, Δ_N) sont déterminés de façon à ce que la probabilité de N_i^C diminue lorsque N_i^C et $N_{k_0:k}^A$ sont différents (*cf.* Partie 7.1.6).

4.6.2 Cas où il y a plusieurs convois

La gestion des hypothèses de nombre de cibles dans un convoi devient plus compliquée lorsque plusieurs convois peuvent être détectés, voire lorsque les convois interagissent entre eux (cas de la séparation d'un convoi en deux convois par exemple). Si un agrégat $\mathcal{A}_{k-1,j}$ détectés et évalués à l'itération $k-1$ peut être mis en correspondance avec plusieurs agrégats détectés à l'itération k , alors l'agrégat $\mathcal{A}_{k-1,j}$ est dupliqué puis estimé avec l'ensemble des agrégats avec lequel il peut être mis en correspondance.

L'ensemble du processus de gestion du nombre de cibles dans les agrégats est décrit dans l'algorithme 4.6.2.

Algorithme 4.6.2 Estimation du nombre de cibles dans un agrégat

$\{\mathcal{A}_{k-1,j}\}_{j=1}^N$: ensemble des agrégats détectés et évalués à $k-1$
 $\hat{x}_{k-1}^{\mathcal{A}_i}$: barycentre de l'agrégat
 $P_{k-1}^{\mathcal{A}_i}$: covariance
0: Input : $N^{\mathcal{A}_i}$: nombre de cibles considérés dans l'agrégat
 $\{\mathcal{A}'_{k,j}\}_{j=1}^{N'}$: ensemble des agrégats détectés à k
 α : seuil pour le fenêtrage statistique

1: $\{\mathcal{A}_{k|k-1,j}\}_{j=1}^{N'} = \text{prédiction}(\{\mathcal{A}_{k-1,j}\}_{j=1}^{N'})$
2: if $N' == 0$ **then**
3: $\{\mathcal{A}_{k,j}\}_{j=1}^N = \{\mathcal{A}'_{k,j}\}_{j=1}^{N'}$
4: else
5: Mise en correspondance des agrégats
6: for $i = 1$ à N' **do**
7: $maj = 0$
8: for $j = 1$ à N' **do**
9: if $\text{test-statistique}(\mathcal{A}'_{k,i}, \mathcal{A}_{k|k-1,j}, \alpha) == 1$ **et** $\mathcal{A}_{k|k-1,j}$ **pas mis à jour** **then**
10: if $N^{\mathcal{A}'_{k,i}} == N^{\mathcal{A}_{k|k-1,j}}$ **then**
11: maj = 1
12: $\mathcal{A}_{k,j} = \text{estimation}(\mathcal{A}_{k|k-1,j}, \mathcal{A}'_{k,i})$
13: end if
14: if $N^{\mathcal{A}'_{k,i}} > N^{\mathcal{A}_{k|k-1,j}}$ **then**
15: $id = \text{choix-cible}(\mathcal{A}_{k|k-1,j})$
16: $\mathcal{A}_{k,j} = \text{estimation}(\mathcal{A}_{k|k-1,j}, \mathcal{A}'_{k,i})$
17: end if
18: if $N^{\mathcal{A}'_{k,i}} < N^{\mathcal{A}_{k|k-1,j}}$ **then**
19: $\mathcal{A}_{k,j} = \text{estimation}(\mathcal{A}_{k|k-1,j}, \mathcal{A}'_{k,i})$
20: end if
21: end if
22: if $\text{test-statistique}(\mathcal{A}'_{k,i}, \mathcal{A}_{k|k-1,j}, \alpha) == 1$ **et** $\mathcal{A}_{k|k-1,j}$ **déjà mis à jour** **then**
23: $\mathcal{A}_{k|k-1,N+1} = \text{duplication}(\mathcal{A}_{k|k-1,j}, \mathcal{A}'_{k,i})$
24: $\mathcal{A}_{k,N+1} = \text{estimation}(\mathcal{A}_{k|k-1,N+1}, \mathcal{A}'_{k,i})$
25: end if
26: end for
27: if $maj == 0$ **then**
28: $\mathcal{A}_{k,N+1} = \text{Création-nv-agregat}(\mathcal{A}'_{k,i})$
29: end if
30: end for
31: end if

Output : $\{\mathcal{A}_{k,j}\}_{j=1}^{N^{\mathcal{A}}}$: ensemble des agrégats mis à jour à k

Conclusion

La modélisation du convoi par les réseaux bayésiens nous permet d'introduire un maximum des propriétés définies dans un convoi. Celle-ci peuvent se traduire sous la forme de contraintes : ainsi nous avons réussi à en intégrer un grand nombre, aussi bien spatio-temporelle, que de vitesse ou encore de type. La représentation par des réseaux bayésiens a ainsi, selon notre point de vue, des avantages qui se plient bien à la problématique :

- une représentation très intuitive des interactions entre les états,
- la possibilité d'introduire des interactions temporelles ce qui est particulièrement intéressant lorsque les données ne sont pas synchronisées.

Cependant, les désavantages de cette représentation graphique peuvent se résumer en trois points :

- difficulté de transformer les données en probabilités, mais cette difficulté est vraie quelle que soit la représentation,
- difficulté d'évaluer les probabilités conditionnelles,
- étape de prise de décision, vraie également quelle que soit la représentation choisie.

Il est à noter que nous avons basé la modélisation sur une approche probabiliste, mais les approches de type crédibiliste sont tout à fait envisageables en utilisant des masses de croyance à la place des probabilités. Dans un premier temps, une approche probabiliste conventionnelle paraît appropriée, notamment pour l'utilisation de toolbox existantes¹, mais l'intégration du modèle dans un cadre crédibiliste paraît très intéressante pour détecter de nouveaux objets d'intérêt et les manœuvres dans un convoi. Les avantages et inconvénients seraient les mêmes à l'exception du fait que les approches crédibilistes modélisent l'ignorance et le conflit. C'est l'objet du chapitre suivant.

¹Kevin Murphy met en ligne gratuite une toolbox matlab pour implémenter les réseaux bayésiens [Murphy 2002]

Les réseaux crédibilistes : prise en compte du conflit entre les sources pour l'amélioration de la détection

Sommaire

5.1 Réseaux bayésiens <i>vs.</i> crédibilistes	138
5.1.1 Généralités sur les modèles graphiques	138
5.1.2 De l'intérêt d'utiliser les fonctions de croyance	138
5.2 Réseaux crédibilistes	140
5.2.1 Description du mécanisme d'inférence	140
5.2.2 Application à la détection de convoi	141
5.3 Réseau crédibiliste dynamique	144
5.3.1 Filtre temporel crédibiliste	144
5.3.2 Application à la détection de convois	145
5.4 Implémentation du réseau crédibiliste	146
5.4.1 Transformation des données en masse de croyance	146
5.4.2 Prise en compte de la direction de déplacement des cibles	146
5.4.3 Estimation du nombre de cibles évoluant dans le sens de l'agrégat	147

Introduction

Dans le chapitre 4, nous avons élaboré un modèle de convoi basé sur un mécanisme de propagation de l'information probabiliste. Dans la partie 1.3, nous avons étudié les avantages et inconvénients des approches probabilistes et crédibilistes. Nous souhaitons donc à présent comparer les deux approches et mettre en œuvre les réseaux crédibilistes afin de prendre en compte le conflit et le doute pour une meilleure interprétation de la situation.

Afin de bien comprendre l'intérêt de l'utilisation des réseaux crédibilistes, nous commençons par mener une réflexion sur l'apport de la théorie crédibiliste par rapport aux réseaux bayésiens en considérant un cas simple (Partie 5.1). Ensuite, nous décrivons le processus d'inférence dans les réseaux crédibilistes ainsi que leur utilisation dans le cadre de la détection de convoi (Partie 5.2). Finalement, de la même façon que les réseaux bayésiens dynamiques intègrent une évolution temporelle des variables, nous présenterons un filtre crédibiliste temporel (Partie 5.3) afin de rendre dynamiques les réseaux crédibilistes dans notre application. Finalement, l'implémentation du réseau crédibiliste pour la détection de convoi est décrite ainsi qu'une amélioration au niveau de la structure du réseau.

5.1 Réseaux bayésiens *vs.* crédibilistes

5.1.1 Généralités sur les modèles graphiques

Les modèles graphiques, formalisés pour la première fois par Pearl [Pearl 1988] dans un cadre probabiliste, sont utilisés très communément dans de nombreuses applications comme le diagnostic médical [Nikovski 2000], l'évaluation de situation [Johansson 2006, Das 2002] ou la biologie [Murphy 1999]. Ils sont d'un formalisme très puissant puisqu'ils permettent de calculer l'évolution des variables d'un système, grâce une technique de représentation de l'information (probabilité, possibilité, ...), tandis que le système est représenté intuitivement par un graphe, composé de nœuds et d'arcs. Les nœuds représentent les différentes variables du système tandis que les arcs représentent les relations de dépendance entre les variables permettant de limiter la combinatoire. Par exemple, dans un cadre probabiliste (réseaux bayésiens), on a la relation fondamentale suivante :

$$P \{s_1, \dots, s_n\} = \prod_{i=1}^n P \{s_i | Pa(s_i)\} \quad (5.1)$$

où $Pa(s_i)$ représente les nœuds parents de s_i .

Les réseaux bayésiens sont particulièrement efficaces lorsque l'on dispose d'une connaissance statistique approfondie du système à modéliser. Ce n'est pas notre cas, c'est pourquoi nous nous intéressons à présent aux réseaux crédibilistes. Ces derniers ont les mêmes caractéristiques que les réseaux bayésiens, à la différence qu'ils sont un mélange entre la théorie des graphes et la théorie des fonctions de croyance (*cf.* Partie 1.3.3). Ils utilisent moins d'information *a priori* et permettent de modéliser l'absence de connaissance. Bien que moins connus par rapport aux réseaux bayésiens, ils sont utilisés dans des applications similaires récentes comme l'analyse de fiabilité de systèmes [Simon 2007] ou l'évaluation de la menace [Benavoli 2007]. Les bases théoriques du processus d'inférence ont été formalisées par Xu et Smets [Xu 1996, Smets 1993]. Contrairement aux réseaux bayésiens, ils s'articulent en deux niveaux. Le premier niveau **crédal** est celui de la représentation de la connaissance, des combinaisons et de l'inférence. À ce niveau, la modélisation est plus fine que pour les probabilités, car pour chaque variable, l'absence ou le manque de connaissance sont modélisés. Le deuxième niveau, appelé **pignistique**, est celui de la prise de décision. Il est adapté aux problématiques de diagnostic par exemple.

5.1.2 De l'intérêt d'utiliser les fonctions de croyance

Pour mieux comprendre les concepts de réseaux crédibilistes et de confiance, prenons l'exemple de l'aide au diagnostic médical (*cf.* Figure 5.1).

Considérons un ensemble Ω de signes cliniques des plus simples (poids, température, pression, ...) aux plus évolués (taux de plaquettes, globules rouges, sucre, ...) car nécessitant des examens médicaux coûteux et/ou lourds pour le patient (IRM, biopsie, ...) tel que $\Omega = \{s_1, \dots, s_n\}$, où s_i correspond à un symptôme.

Considérons $\Theta = \{\theta_1, \dots, \theta_m\}$ l'ensemble des maladies caractérisées par les symptômes Ω et \mathbf{G} le graphe décrivant les relations de dépendance entre l'ensemble des symptômes et l'ensemble des maladies.

Dans l'exemple présenté en figure 5.1, une grippe est caractérisée par des courbatures, une toux et une forte fièvre, tandis qu'une angine a pour symptôme de la fièvre, une forte toux et pas de courbature. En décrivant ainsi intuitivement les symptômes des maladies,




Fig. 5.1 – Modèle graphique représentant un cas de diagnostic médical

nous faisons intervenir les notions de forte fièvre ou de forte toux, ainsi nous comprenons bien que certains symptômes sont plus importants que d'autres pour décrire une maladie. Cette notion d'importance peut se traduire de deux manières dans le formalisme des réseaux bayésiens/de croyance selon :

- Choix du cadre de discernement : pour la toux par exemple, on peut considérer simplement la présence ou l'absence du symptôme $toux = \{oui, non\}$ ou alors on peut déjà considérer une graduation dans le symptôme, ainsi $toux = \{forte, moyenne, faible, abs\}$
- Établissement des probabilités/masses de croyance conditionnelles.

Dans un système probabiliste, le doute n'est pas modélisé. Par conséquent, à chaque nouveau signe vital mesuré ou examen médical, la probabilité pour le patient d'avoir telle ou telle maladie est calculée. Cependant, sans modélisation du doute, pour chaque nouvelle donnée en entrée, la probabilité d'avoir chacune des maladies est calculée sans modéliser le fait que ce nouveau paramètre est discriminatif ou non pour telle ou telle maladie.

Par conséquent, si un patient a un risque modéré d'avoir une maladie (imaginons que la probabilité qu'il ait la grippe soit de 0.5), les probabilités ne permettent pas de savoir si c'est parce que les symptômes se manifestent faiblement ou si c'est parce qu'il manque des examens médicaux pertinents pour en juger. Imaginons qu'on ne sache pas si le patient a des courbatures ou non, mais qu'il manifeste par contre une forte fièvre et une forte toux. Avec les réseaux bayésiens, la probabilité que le patient ait une angine sera probablement plus forte que la probabilité qu'il ait une grippe par manque d'informations, alors qu'avec les réseaux crédibilistes, on verra qu'il subsiste un doute quant au fait que le patient ait la grippe et on souhaitera savoir si il a des courbatures ou non.

Globalement, les réseaux de croyances pallient le problème du manque d'information par la modélisation du doute. Si on ne dispose pas d'informations ou si les informations sont incomplètes, alors le fait est clairement modélisé. Le médecin peut ainsi juger de la nécessité d'effectuer des examens médicaux supplémentaires.

Dans un réseau crédibiliste, comme cela se fait couramment pour les réseaux bayésiens, la notion de dépendance temporelle peut intervenir. Dans notre cas de figure, cette notion est très importante car les symptômes décrits ont une durée variable. Ainsi, le réseau crédibiliste doit être dynamique car il est important de pouvoir affaiblir les informations au fur et à mesure que le temps passe depuis la dernière mesure. Par exemple, une information

de température n'est plus fiable au bout de quelques heures car l'état du patient a évolué. Ou au contraire, une information sur la présence ou non d'une tumeur est indépendante du temps au regard de la durée d'un diagnostic médical. Nous décrivons à présent le mécanisme d'inférence d'un réseau crédibiliste et comment il est utilisé dans le modèle convoi.

5.2 Réseaux crédibilistes

5.2.1 Description du mécanisme d'inférence

Un modèle graphique de base illustre le concept de réseaux crédibiliste en figure 5.2. Les nœuds S_1 et S_2 sont les nœuds parents ; leurs distributions de masses sont des entrées à chaque itération k . La distribution de masses de croyances de S_3 est calculée à chaque itération k par propagation des distributions de masses de croyance de S_1 et S_2 . Avant de




Fig. 5.2 – Un exemple basique de réseau crédibiliste

décrire le mécanisme d'inférence à travers le réseau, il faut préciser comment ce dernier est initialisé :

1. **Établissement des masses de croyances conditionnelles :** Dans le cadre des réseaux probabilistes, la première étape consiste à établir les probabilités conditionnelles $P\{S_3|S_1, S_2\}$ (cf. partie 4.5) de taille $|\Omega_1| \times |\Omega_2| \times |\Omega_3| = 2 \times 2 \times 2 = 8$. Cette taille augmente selon le nombre d'états envisagés pour les variables aléatoires et plus généralement, selon le nombre de nœuds parents. Par analogie, dans le cadre des réseaux crédibilistes, on souhaite établir des masses de croyance conditionnelles. Cependant, ces dernières sont établies par rapport à chaque nœud parent indépendamment des autres. Cela limite avantageusement la combinatoire. Car si les distributions de masses de croyances étaient établies conjointement, alors le nombre de masses conditionnelles à établir serait de $2^{|\Omega_1|} \times 2^{|\Omega_2|} \times 2^{|\Omega_3|} = 4 \times 4 \times 4 = 64$. Dans notre cas, on souhaite donc plus simplement établir, $\forall i \in \{1, 2\}$, la distribution de masses de croyance $m^{\Omega_3}[S_i]$ sur l'ensemble Ω_3 conditionnellement aux différents états possibles pour S_i .

Cependant, il faut tout de même noter que seules les masses de croyance conditionnellement au fait que le nœud i est dans l'état S_i ou \bar{S}_i peuvent être calculées. La masse de croyance sachant que le nœuds i est dans l'état Ω_i ne peut pas être intuitivement établie mais doit être calculée, $\forall i \in \{1, 2\}$, en utilisant la DRC dont l'expression est décrite en (1.48), $\forall B \subseteq \Omega_3$:

$$b^{\Omega_3}[\Omega_i](B) = b^{\Omega_3}[S_i](B).b^{\Omega_3}[\bar{S}_i](B) \quad (5.2)$$

où $b^{\Omega_3}[\Omega_i](S_3)$ est l'implicabilité de S_3 connaissant S_i qui est définie en (1.41).

2. **Choix des coefficients d'atténuation** : Quand un nœud dépend de plusieurs autres nœuds, il est possible de modifier l'importance accordée à chacun des nœuds parents en utilisant des coefficients d'atténuation. D'un autre point de vue, chaque nœud parent peut être vu comme une source d'informations indépendante des autres, dont l'influence va être plus ou moins pondérée en fonction de sa fiabilité. L'atténuation se fait en utilisant la formule d'affaiblissement des sources (1.53). Finalement, cette opération est très similaire à celle réalisée en (4.32) pour les réseaux bayésiens.

Nous décrivons à présent le mécanisme d'inférence. Celui-ci est décomposé en opérations basiques pour le réseau crédibiliste décrit en figure 5.2.

1. **Propagation de l'information** : L'information de chaque nœud parent S_i est propagée au nœud S_3 . La distribution de masses de croyance obtenue s'écrit $m_{i \rightarrow 3}^\Omega$. Elle se calcule à travers l'utilisation des plausibilités (cf. equation (1.39)) en utilisant le théorème de Bayes généralisé (1.50) tel que, $\forall B \subseteq \Omega_3$:

$$pl_{i \rightarrow 3}^{\Omega_3}(B) = \sum_{C \subseteq \Omega_3} pl^{\Omega_3}[C](B) \cdot \tilde{m}^{\Omega_i}(C) \quad (5.3)$$

2. **Affaiblissement** : À partir des coefficients d'affaiblissement α_i établis pour chaque nœud S_i , la formule (1.53) est appliquée sur les distributions de masses de croyance propagée $m_{i \rightarrow 3}^{\Omega_3}$, $\forall i \in \{1, 2\}$ dans le but d'obtenir les distributions de masses de croyance affaiblies $\alpha_i m_{i \rightarrow 3}^{\Omega_3}$.
3. **Combinaison des informations issues de plusieurs nœuds parents** : Les distributions de masses de croyance affaiblies sont finalement utilisées en utilisant l'implicabilité pour une combinaison CRC (cf (1.46)) telles que $\forall B \subseteq \Omega_3$:

$$q^{\Omega_3}(B) = \alpha_1 q_{1 \rightarrow 3}^{\Omega_3}(B) \cdot \alpha_2 q_{2 \rightarrow 3}^{\Omega_3}(B) \quad (5.4)$$

Il est entendu que ce mécanisme de propagation peut être appliqué seulement sur des réseaux simples. Avec des réseaux plus complexes, il faut se servir d'une méthode inspirée des techniques d'inférence utilisées pour les réseaux bayésiens, car ce problème est généralement NP-complet. Ainsi Yaghlane a proposé une adaptation de l'algorithme d'inférence de Pearl dans [Yaghlane 2008]. À notre avis, beaucoup de voies restent à explorer dans ce domaine, notamment un mécanisme de propagation des masses de croyance en utilisant le mécanisme JLO¹. [Jensen 1990]

5.2.2 Application à la détection de convoi

Dans cette partie, nous appliquons la méthode de propagation de l'information décrite en 5.2 sur le modèle de convoi. Le schéma 5.3 illustre la démarche proposée pour évaluer la variable aléatoire S_9^k .

Une distribution de masses de croyance est écrite sous la forme d'un vecteur de longueur 4 tel que $m^{\Omega_i}(S_i) = [m(\emptyset) \ m(S_i) \ m(\bar{S}_i) \ m(\Omega_i)]^T$.

Parmi les étapes de modélisation hors ligne :

- **Établissement des masses de croyance conditionnelles** : il s'agit de la toute première étape. En utilisant des raisonnements du type : « Si la vitesse est supérieure à 80

¹Le mécanisme JLO (du nom de ses auteurs : Jensen, Lauritzen et Olesen) est une technique d'inférence décrite en annexe A




Fig. 5.3 – Décomposition du réseau crédibiliste - Les couleurs renvoient aux différentes étapes de propagation de l'information décrite dans cette partie.

km.h⁻¹, alors l'agrégat n'est pas un convoi » et « Si la vitesse est inférieure à 80 km.h⁻¹, alors l'agrégat peut être un convoi, ou non », on peut proposer la distribution de masses de croyance de S_3 conditionnellement à S_1 suivante, telle que $\forall B \in \Omega_1$:

$$m^{\Omega_3}[B] = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0.5 & 0 & 0 \\ 0 & 0 & 0.9 & 0 \\ 0 & 0.5 & 0.1 & 1 \end{bmatrix} \quad (5.5)$$

On a ainsi quatre distributions de masses, qui correspondent aux 4 colonnes, pour la variable S_3 conditionnellement aux états pris par S_1 : $m^{\Omega_3}[\emptyset]$, $m^{\Omega_3}[S_1]$, $m^{\Omega_3}[\bar{S}_1]$ et $m^{\Omega_3}[\Omega_1]$. Cette matrice est utilisée pour l'étape suivante de propagation de l'information (cf. équation 5.10). Si la vitesse est supérieure à 80 km.h⁻¹, $m^{\Omega_1}(\bar{S}_1) = 1$, et on modélise le fait que ce n'est sûrement pas un convoi : $m^{\Omega_3}[\bar{S}_1](\bar{S}_3) = 0.9$. A l'inverse, si la vitesse est inférieure à 80 km.h⁻¹, alors l'agrégat peut être un convoi ou non tel que $m^{\Omega_3}[S_1](S_3) = 0.5$. Sinon, le doute et le conflit sont redistribués sur eux-mêmes. Concernant les nœuds S_2 et S_4 , on conserve exactement le même raisonnement. Par conséquent, on utilise la même matrice de masses conditionnelles pour les éléments de Ω_2 et Ω_4 .

À noter que nous avons testé plusieurs jeux de distribution de masses de croyance conditionnelles et nous présentons ici le jeu qui nous paraît donner les meilleurs résultats, comme nous le montrerons dans le chapitre 7.

Pour les autres nœuds, les critères sont plus discriminatifs. Par exemple, le raisonnement est tel que pour S_6 : « Si la distance entre les véhicules de l'agrégat est constante, alors c'est un convoi ; sinon ce n'en est pas un. » On obtient donc des

matrices conditionnelles telles que $\forall B \subseteq \Omega_6$:

$$m^{\Omega_8}[B] = \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0.9 & 0 & 0 \\ 0 & 0 & 0.9 & 0 \\ 0 & 0.1 & 0.1 & 1 \end{bmatrix} \quad (5.6)$$

Finalement, on utilise la même matrice pour les nœuds S_7 , S_3, S_5 , et S_8 :

$$m^{\Omega_8}[S_7] = m^{\Omega_9}[S_3] = m^{\Omega_9}[S_5] = m^{\Omega_9}[S_8] = m^{\Omega_8}[S_6] \quad (5.7)$$

Il faut noter que la dernière colonne des matrices est obtenue en utilisant l'équation (5.2). On aurait pu plus simplement la calculer en sachant que la somme des lignes est égale à 1, mais dans un cadre plus général, lorsque le nombre d'états est supérieur à 2, il faut bien utiliser la formule (5.2).

- **Établissement des coefficients d'atténuation** : comme nous l'avons fait dans le chapitre 4, il est possible de pondérer l'importance accordée à chaque variable comme cela se traduit dans l'équation (4.32). En utilisant les mêmes relations on obtient :

$$\alpha_3 = 0.3 \quad \alpha_4 = 0.2 \quad \alpha_5 = 0.2 \quad \alpha_8 = 0.3 \quad (5.8)$$

L'importance accordée aux nœuds S_1 et S_2 est la même ; de même que pour S_6 et S_7 . Par conséquent :

$$\alpha_1 = 1 \quad \alpha_2 = 1 \quad \alpha_6 = 1 \quad \alpha_7 = 1 \quad (5.9)$$

Nous présentons à présent les étapes itératives de mise à jour de l'état du système.

- **Propagation de l'information** : les distributions de masses de croyance intermédiaires sont calculées conformément à l'équation (5.10) pour les nœuds S_3 , S_8 et S_9 à partir des distributions de masse de croyance calculées sur les nœuds en racine. Par exemple, si l'information issue de S_1 est propagée au nœud S_3 , on calcule $\forall B \subseteq \Omega_3$:

$$pl_{1 \rightarrow 3}^{\Omega_3}(B) = \sum_{C \subseteq \Omega_3} pl^{\Omega_3}[C](B) \cdot \tilde{m}^{\Omega_1}(C) \quad (5.10)$$

- **Combinaison des distributions de masses de croyance** : cette mesure est faite en utilisant les distributions de masses de croyance intermédiaires et les coefficients d'affaiblissement en utilisant l'équation (5.4). Ainsi pour le nœud S_3 , les informations issues de S_1 et S_2 sont combinées, telles que la distribution d'implicabilités \tilde{q}^{Ω_3} s'écrit, $\forall B \subseteq \Omega_3$:

$$\tilde{q}^{\Omega_3}(B) = \alpha_1 q_{1 \rightarrow 3}^{\Omega_3}(B) \cdot \alpha_2 q_{2 \rightarrow 3}^{\Omega_3}(B) \quad (5.11)$$

Le nœud S_8 est calculé de la même manière $\forall B \subseteq \Omega_8$:

$$\tilde{q}^{\Omega_8}(B) = \alpha_6 q_{6 \rightarrow 8}^{\Omega_8}(B) \cdot \alpha_7 q_{7 \rightarrow 8}^{\Omega_8}(B) \quad (5.12)$$

Et le nœud S_9 se calcule à partir des masses issues des nœuds S_3 , S_4 , S_5 et S_8 , $\forall B \subseteq \Omega_9$:

$$\tilde{q}^{\Omega_9}(B) = \alpha_3 q_{3 \rightarrow 9}^{\Omega_9}(B) \cdot \alpha_4 q_{4 \rightarrow 9}^{\Omega_9}(B) \cdot \alpha_5 q_{5 \rightarrow 9}^{\Omega_9}(B) \cdot \alpha_8 q_{8 \rightarrow 9}^{\Omega_9}(B) \quad (5.13)$$

Cependant, dans le cadre probabiliste, le réseau est dynamique car le nœud S_9 dépend de son état à l'itération précédente. Nous présentons maintenant le filtre crédibiliste, qui sera utilisé pour rendre le réseau crédibiliste dynamique.

5.3 Réseau crédibiliste dynamique

5.3.1 Filtre temporel crédibiliste

Dans le cadre de la modélisation, un système physique est mathématiquement défini par un ensemble de variables aléatoires reflétant l'état global du système à un instant donné. Un système dit **dynamique** ou **non-stationnaire**, est un système physique dont l'ensemble ou une partie des variables évoluent au cours du temps. L'analyse d'un tel système a pour objectif d'étudier l'état du système à l'instant courant en prenant en compte la connaissance que nous en avons de l'état précédent. Pour se faire, une fonction de transition F_k^Ω d'un état à l'instant k vers un état à l'instant $k + 1$ peut être définie. Cette idée d'utiliser une technique de filtrage dans un cadre probabiliste a été initiée par Smets et Ristic [Smets 2007b] dans le cadre d'un filtrage de Kalman crédibiliste. Une autre solution, proposée par Smets dans le cadre du filtrage, est d'utiliser la notion de mémoire à facteur d'oubli. Si une information n'est pas mise à jour, alors cette dernière est affaiblie [Smets 2007a] (cf. équation (1.53)). Finalement, la notion de filtre temporel crédibiliste est introduite par Ramasso dans [Ramasso 2006, Ramasso 2007a]. Le principe de ce filtre est illustré par la figure 5.4.

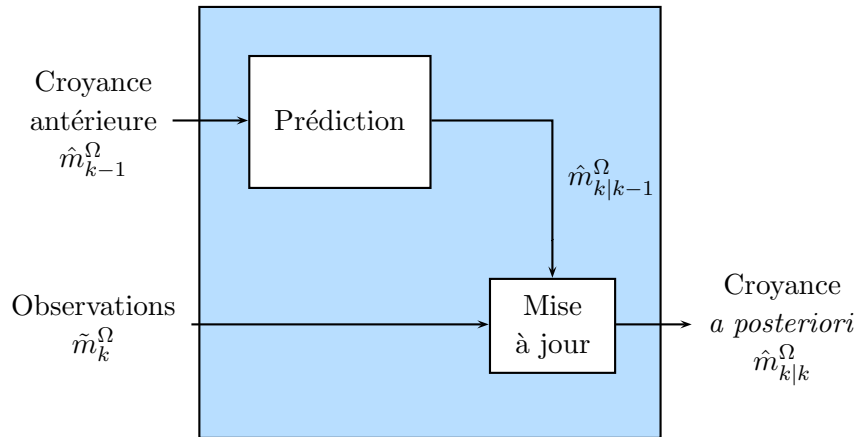


Fig. 5.4 – Principe du filtre temporel crédibiliste

La masse de croyance prédite $\hat{m}_{k|k-1}^{\Omega_i}(S_i)$ sur la variable S_i à l'itération k s'écrit, $\forall B \subseteq \Omega_i$:

$$\hat{m}_{k|k-1}^{\Omega_i}(B) = F_k^{\Omega_i} . \hat{m}_{k-1|k-1}^{\Omega_i}(B) \quad (5.14)$$

avec $\hat{m}_{k-1|k-1}^{\Omega_i}$ est la masse de croyance à l'itération $k - 1$ et $F_k^{\Omega_i}$ est le modèle d'évolution temporel de la variable S_i (bloc prédiction).

En considérant le cas où la variable aléatoire S_i est binaire ($\Omega_i = \{S_i, \bar{S}_i\}$), on utilise la notation vectorielle suivante pour représenter la distribution de masses de croyance estimée $\hat{m}_{k|k}^{\Omega_i}$:

$$\hat{m}_{k|k}^{\Omega_i} = [\hat{m}_{k|k}^{\Omega_i}(\emptyset) \quad \hat{m}_{k|k}^{\Omega_i}(S_i) \quad \hat{m}_{k|k}^{\Omega_i}(\bar{S}_i) \quad \hat{m}_{k|k}^{\Omega_i}(\Omega_i)]^T \quad (5.15)$$

Finalement, le modèle d'évolution temporelle d'une itération $k - 1$ à l'itération k est

de taille $2^{|\Omega_i|} \times 2^{|\Omega_i|}$ et s'écrit :

$$F_k^{\Omega_i} = [F_k^{\Omega_i}(\emptyset) \quad F_k^{\Omega_i}(S_i) \quad F_k^{\Omega_i}(\bar{S}_i) \quad F_k^{\Omega_i}(\Omega_i)] \quad (5.16)$$

avec $F_k^{\Omega_i}(\emptyset) = [1 \ 0 \ 0 \ 0]^T$ et $F_k^{\Omega_i}(\Omega_i) = [0 \ 0 \ 0 \ 1]^T$ car tout le conflit/doute est transféré sur lui-même. $F_k^{\Omega_i}(S_i)$ (*resp.* $F_k^{\Omega_i}(\bar{S}_i)$) représente le modèle d'évolution du nœud S_i si sa valeur est vraie (*resp.* fausse). Dans ce cas, la masse de croyance sur S_i (*resp.* \bar{S}_i) est partiellement transférée sur S_i (*resp.* \bar{S}_i) selon une mesure de confiance $\alpha_{\mathcal{T}}$ (*resp.* $\alpha_{\mathcal{F}}$) telle que :

$$F_k^{\Omega_i}(S_i) = [0 \ \alpha_{\mathcal{T}} \ 0 \ 1 - \alpha_{\mathcal{T}}]^T \quad F_k^{\Omega_i}(\bar{S}_i) = [0 \ 0 \ \alpha_{\mathcal{F}} \ 1 - \alpha_{\mathcal{F}}]^T \quad (5.17)$$

Finalement, la distribution de masses de croyance prédite $\hat{m}_{k|k-1}^{\Omega_i}(S_i)$ obtenue par l'équation (5.14) est combinée avec la distribution de masses de croyance mesurée $\tilde{m}_k^{\Omega_i}(S_i)$ (bloc mise à jour). C'est la combinaison CRC (*cf.* équation (1.46)) qui est utilisée car elle met en valeur le conflit entre les deux éléments combinés. On obtient donc, $\forall B \subseteq \Omega_i$:

$$\hat{m}_{k|k}^{\Omega_i}(B) = \tilde{m}_k^{\Omega_i}(B) \odot \hat{m}_{k|k-1}^{\Omega_i}(B) \quad (5.18)$$

5.3.2 Application à la détection de convois

Dans le réseau présenté en figure 4.4, la variable S_9 dépend de son état à l'itération précédente. Nous appliquons donc un filtre crédibiliste sur ce nœud afin d'obtenir un réseau crédibiliste dynamique (Dynamic Evidential Network : DEN en anglais).

Le filtre s'applique en deux étapes. Lors de la première étape de prédiction, on prévoit la distribution de masses de croyance $\hat{m}_{k|k-1}^{\Omega_9}$ de la variable S_9 à l'itération k en suivant le modèle $F_k^{\Omega_9}$:

$$\hat{m}_{k|k-1}^{\Omega_9} = F_k^{\Omega_9} . \hat{m}_{k-1|k-1}^{\Omega_9} \quad (5.19)$$

Le modèle d'évolution $F_k^{\Omega_9}$ s'écrit tel que :

$$F_k^{\Omega_9} \begin{bmatrix} 1 & 0 & 0 & 0 \\ 0 & 0.9 & 0 & 0 \\ 0 & 0 & 0.5 & 0 \\ 0 & 0.1 & 0.5 & 1 \end{bmatrix} \quad (5.20)$$

Ce modèle traduit le fait, que si un convoi est détecté à l'itération précédente, alors on a une forte croyance ($\alpha_{\mathcal{T}} = 0.9$) d'en avoir un à l'itération suivante. Tandis que même si aucun convoi n'est détecté à l'itération précédente, il peut en apparaître un à n'importe quel moment ($\alpha_{\mathcal{F}} = 0.5$).

Finalement, lors de l'étape de mise à jour, nous combinons la distribution de masses mesurée $\tilde{m}_k^{\Omega_9}$ pour le nœuds S_9 et la masse prédite $\hat{m}_{k|k-1}^{\Omega_9}$ telle que la distribution de masses mise à jour $\hat{m}_{k|k}^{\Omega_9}$ soit égale à :

$$\hat{m}_{k|k}^{\Omega_9} = \tilde{m}_k^{\Omega_9} \odot \hat{m}_{k|k-1}^{\Omega_9} \quad (5.21)$$

Ainsi, comme nous le verrons dans le chapitre 7, lorsque le convoi ne suit pas le modèle de comportement défini par les opérationnels, du conflit apparaît sur le nœud S_9 .

Dans un contexte opérationnel, il faut considérer que le convoi n'évolue pas seul sur le théâtre des opérations ; il croise et double d'autres cibles qui viennent alors interférer

dans l'évaluation qui est faite du convoi. De plus, le convoi peut en interne réaliser des manœuvres (séparation, intégration d'une nouvelle cible, ...). Dans le but de qualifier ces manœuvres, nous pourrions étudier le doute et le conflit sur les différents nœuds du réseau, afin de reconnaître les manœuvres intrinsèques ou extrinsèques liées au convoi.

5.4 Implémentation du réseau crédibiliste

5.4.1 Transformation des données en masse de croyance

Nous souhaitons, à partir des données, calculer les distributions de masses \tilde{m}^{Ω_i} pour tous les nœuds racines S_i . Dans le chapitre précédent, nous proposons de transformer les données en probabilités en utilisant une transformation de Rayleigh ou des opérateurs de transformation floue (*cf.* Partie 4.4). Nous obtenions alors des distributions de probabilités $\{P\{S_i\}, P\{\bar{S}_i\}\}$. Dans le cadre des fonctions de croyance, nous utilisons les mêmes transformations et proposons la distribution de masses de croyance en utilisant la relation suivante :

$$\left\{ \begin{array}{l} \tilde{m}^{\Omega_i}(\phi) = 0 \\ \tilde{m}^{\Omega_i}(S_i) = \begin{cases} P\{S_i\} & \text{si } P\{S_i\} \geq 0.5 \\ 0 & \text{sinon} \end{cases} \\ \tilde{m}^{\Omega_i}(\bar{S}_i) = \begin{cases} P\{\bar{S}_i\} & \text{si } P\{\bar{S}_i\} > 0.5 \\ 0 & \text{sinon} \end{cases} \\ \tilde{m}^{\Omega_i}(\Omega_i) = \begin{cases} 1 - P\{S_i\} & \text{si } P\{S_i\} \geq 0.5 \\ 1 - P\{\bar{S}_i\} & \text{sinon} \end{cases} \end{array} \right. \quad (5.22)$$




Fig. 5.5 – Opérateur de transformation d'une distribution de probabilité en masses - relativement à l'équation (5.22)

5.4.2 Prise en compte de la direction de déplacement des cibles

Dans le chapitre 4, nous avons élaboré un modèle graphique décrivant l'objet convoi qui prend en compte un maximum de contraintes spatiale, temporelle, cinématique et de type (cf. Figure 4.4). Comme nous le montrerons dans le chapitre 7, ce premier modèle donne de bon résultats. Cependant, il ne prend pas en compte les contraintes liées au comportement de groupe. Sur l'idée simple que deux cibles qui se croisent ne peuvent pas appartenir au même convoi, nous proposons d'améliorer le modèle initialement proposé en ajoutant le critère « Toutes les cibles considérées dans le convoi évoluent dans le même sens » au niveau du critère vitesse S_3 .

Une amélioration au niveau de la structure du réseau est donc apportée. Elle est décrite dans la figure 5.6.

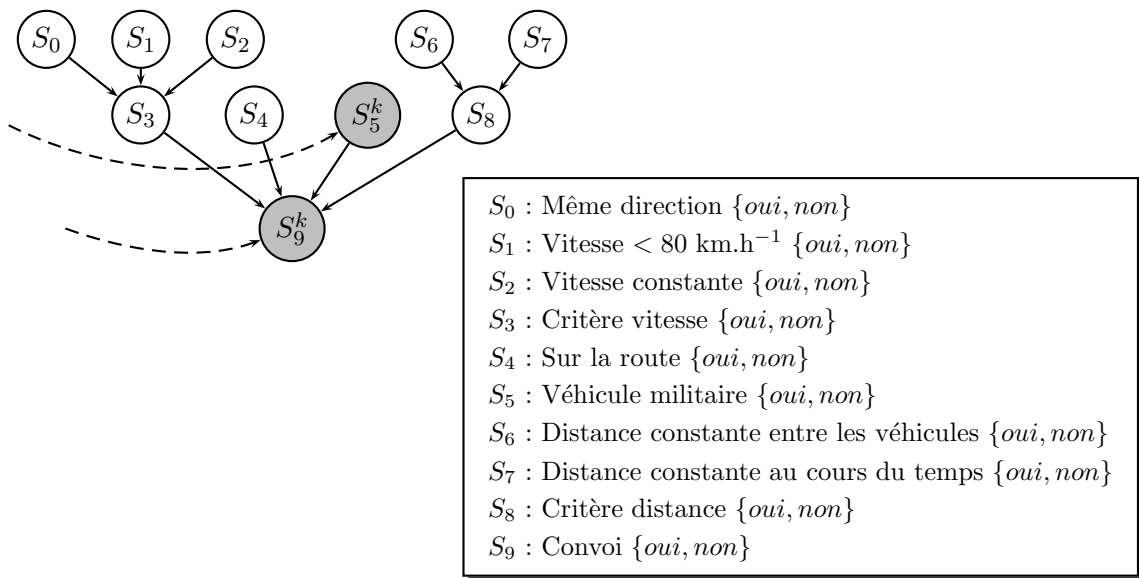


Fig. 5.6 – Un deuxième modèle pour la modélisation de convois. Les nœuds gris représentent les v.a. S_i^k qui dépendent de leur état à l'itération précédente.

Le critère vitesse S_3 dépend donc de la nouvelle variable aléatoire S_0 qui permet de prendre en compte le sens de déplacement des cibles dans l'agrégat. Cette dernière est évaluée de la manière suivante :

$$m^{\Omega_0}(S_0) = \begin{cases} 1 & \text{si } N^{\mathcal{A}} = N_{ms} \\ 0 & \text{si } N^{\mathcal{A}} \neq N_{ms} \end{cases} \quad m^{\Omega_0}(\Omega_0) = \begin{cases} 0 & \text{si } N^{\mathcal{A}} = N_{ms} \\ 1 & \text{si } N^{\mathcal{A}} \neq N_{ms} \end{cases} \quad (5.23)$$

où $N^{\mathcal{A}}$ est le nombre de cibles considéré pour le convoi potentiel et N_{ms} est le nombre de cibles évoluant dans le même sens.

5.4.3 Estimation du nombre de cibles évoluant dans le même sens que l'agrégat

Afin d'évaluer un convoi au milieu du trafic civil, il faut déterminer si les cibles considérées dans l'agrégat évoluent dans la même direction ou non. Comme nous l'avons décrit dans la partie 4.6, en considérant $\{\mathcal{A}_{k-1,i}\}_{i=1}^{N^{\mathcal{A}}}$ l'ensemble des $N^{\mathcal{A}}$ agrégats détectés

à l'itération $k - 1$, si à l'itération k , un nouvel agrégat \mathcal{A}_k est détecté, un fenêtrage statistique est réalisé autour des positions prédites des agrégats $\{\hat{x}_{k|k-1}^{\mathcal{A}_j}\}_{j=1}^{\mathbf{N}^{\mathcal{A}}}$ pour voir s'il peut être mis en correspondance avec un des agrégats précédemment détectés. En entrée, on considère $\{\hat{x}_{k,j}\}_{j=1}^{\mathbf{N}^{\mathcal{A}}}$ l'ensemble des cibles appartenant à l'agrégat détecté à l'itération courante et $\{\mathcal{A}_{k-1,j}\}_{j=1}^{\mathbf{N}^{\mathcal{A}}}$ l'ensemble des agrégats détectés et évalués à l'itération précédente. Nous nous limitons volontairement au cas où il n'y a qu'un seul agrégat détecté à l'itération courante pour plus de facilité dans l'explication de l'algorithme. L'algorithme de traitement peut être décrit de la façon suivante. L'évaluation de la cohérence du sens de déplacement est réalisée par l'étude de la cinématique des $\mathbf{N}^{\mathcal{A}}$ cibles $\{\hat{x}_{k,j}\}_{j=1}^{\mathbf{N}^{\mathcal{A}}}$ appartenant à un agrégat et relativement à l'évaluation qui a été faite des $\mathbf{N}^{\mathcal{A}}$ agrégats $\{\mathcal{A}_{k-1,i}\}_{i=1}^{\mathbf{N}^{\mathcal{A}}}$ détectés et évalués à l'itération précédente. Chaque agrégat $\mathcal{A}_{k-1,i}$ est caractérisé à l'itération $k - 1$ par son état $\hat{x}_{k-1}^{\mathcal{A}_i}$, sa covariance $P_{k-1}^{\mathcal{A}_i}$ et son nombre de cibles considéré $N^{\mathcal{A}_i}$.

L'opération d'évaluation du nombre de cibles évoluant dans le même sens est réalisée en plusieurs étapes qui sont illustrées par l'exemple de la figure 5.7. Ainsi, dans la figure 5.7-(a), on dispose des états estimés $\hat{x}_{k,i}$ de quatre cibles appartenant à un agrégat à l'itération k et de la liste $\mathcal{I}^{\mathcal{A}}$ indiquant l'ordre de circulation des cibles. Partant de l'hypothèse qu'il n'y a que deux directions possibles pour une cible (notées 1 et 2), on souhaite obtenir une liste *sens* de même taille que $\mathcal{I}^{\mathcal{A}}$, définie telle que l'élément i de la liste est égal à 1 si la $i^{\text{ème}}$ cible de la liste $\mathcal{I}^{\mathcal{A}}$ évolue dans le sens 1, tandis qu'il est égale à 2 si la $i^{\text{ème}}$ cible évolue dans le sens 2. Par ailleurs, si la cible i a une vitesse nulle, alors $\text{sens}(i) = 0$. Cette liste est obtenue en réalisant deux opérations élémentaires **init-sens** et **transfo-sens** décrites par la suite.

La deuxième étape (Figure 5.7-(b)) sert à positionner la direction des cibles de l'agrégat par rapport aux deux agrégats détectés à l'itération précédente. Si $\text{sens}(i) = 1$, alors la $i^{\text{ème}}$ cible de la liste $\mathcal{I}^{\mathcal{A}}$ évolue dans le même sens que l'agrégat détecté à l'itération précédente $\mathcal{A}_{k-1,j}$ et $\text{sens}(i) = 2$ sinon. Soient deux agrégats notés ① et ② dans la figure 5.7-(b), l'orientation de leur vitesse est dans le sens dénote 2. L'opération **inv-sens** permet d'indexer les cibles qui évoluent dans le même que $\mathcal{A}_{k-1,j}$ par 1 et les autres par 2.

Dans une première étape, on regarde si l'agrégat détecté peut être mis en correspondance avec un des agrégats détectés précédemment en utilisant un test statistique du ξ^2 comme celui décrit pour l'association piste-mesure en (1.103) en remplaçant la mesure par la position du barycentre de l'agrégat détecté à l'itération courante.

Si l'agrégat détecté \mathcal{A}_k à l'itération courante ne peut être mis en correspondance avec aucun agrégat détecté précédemment, alors on initialise un nouvel agrégat $\mathcal{A}_{k,j}$ et par défaut le nombre de cibles considérés dans cet agrégat est le nombre de cibles évoluant dans le même sens N_{ms} .

Si l'agrégat \mathcal{A}_k détecté à l'itération courante peut être mis en correspondance avec un agrégat détecté précédemment, noté $\mathcal{A}_{k-1,j}$, alors on calcule le nombre de cibles évoluant dans le même sens que $\mathcal{A}_{k-1,j}$. Cela nécessite plusieurs opérations intermédiaires. La première opération est décrite comme « **init-sens** » dans le pseudo-algorithme. On suppose que l'ensemble des cibles $\{\hat{x}_{k,j}\}_{j=1}^{\mathbf{N}^{\mathcal{A}}}$ est trié par ordre de succession spatiale comme décrit en 4.1.2. Une liste *sens* de longueur égale au nombre de cibles est initialisée.

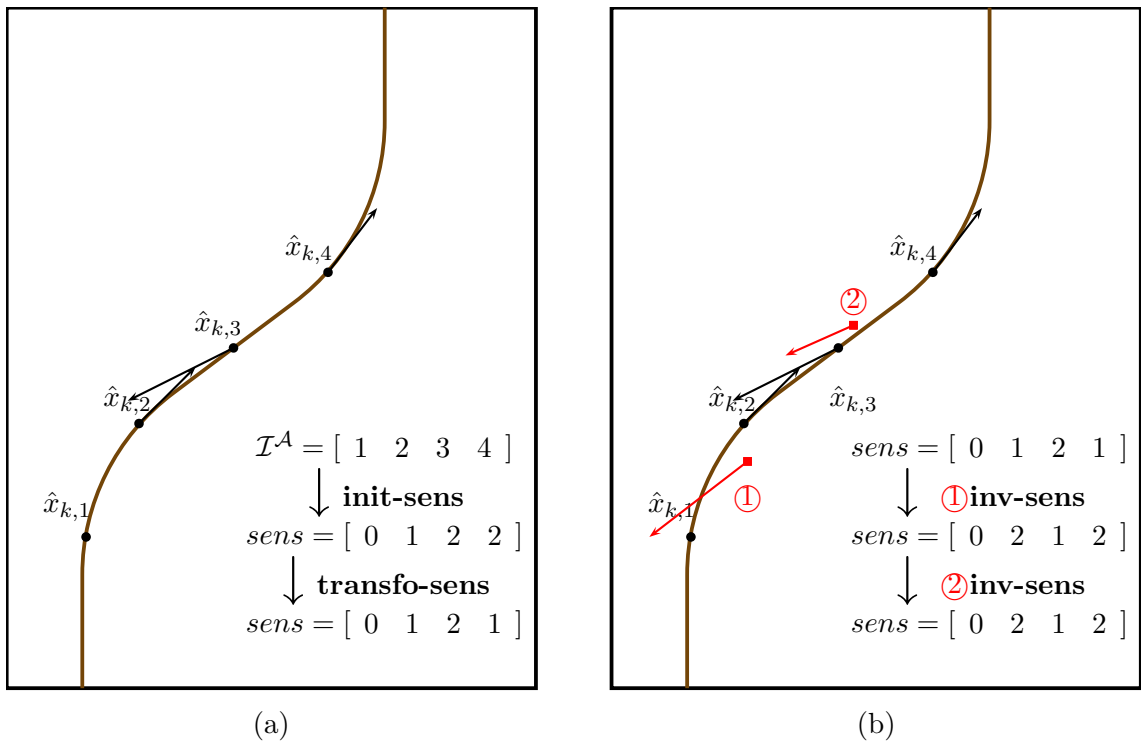


Fig. 5.7 – Opérations pour calculer le nombre de cibles évoluant dans le même sens - Les flèches rouges représentent l'état d'un agrégat évalué à l'itération précédente mis en correspondance.

Si une cible i a une vitesse nulle alors $sens(i) = 0$. Si les vecteurs vitesse de deux cibles successives $i - 1$ et i forment un angle inférieur $\pi/2$, alors elles sont dans le même sens et $sens(i) = 1$. Au contraire si les deux cibles $i - 1$ et i forment un angle supérieur $\pi/2$, alors elles ne vont pas dans le même sens et $sens(i) = 2$. L'opération « **transfo-sens** » permet d'obtenir une liste telle que les cibles peuvent évoluer dans deux sens. Les cibles indexé par 1 évoluent dans un sens, les cibles indexées par 2 évoluent dans l'autre sens. Cette opération est nécessaire comme cela est illustré par la figure 5.7-(a).

Finalement, une troisième opération notée « **inv-sens** » permet d'obtenir une liste telle qu'un élément est égal à 0 si la cible a une vitesse nulle, égal à 1 si la cible évolue dans le même sens que l'agrégat mis en correspondance $\mathcal{A}_{k-1,j}$ (et pas par rapport à la cible précédente) et égal à 2 si la cible évolue dans le sens opposé à $\mathcal{A}_{k-1,j}$. Pour cela, on regarde si la cible la plus proche de l'agrégat évolue dans le même sens ($sens = 1$) et si l'angle formé leur vecteur vitesse est inférieur à $\pi/2$. Cette troisième opération se comprend plus facilement en regardant la figure 5.7-(b). La masse de croyance de la variable S_0 peut alors être calculée selon l'équation (5.23).

Concernant les cibles ayant une vitesse nulle, un traitement particulier leur est réservé pour évaluer le nombre de cibles allant dans le même sens que l'agrégat avec lequel elles sont mises en correspondance. Les cibles ayant une vitesse nulle proviennent de pistes qui viennent d'être initialisées (une estimation ne peut pas fournir une valeur nulle).

Nous n'avons donc *a priori* aucune information sur leur orientation. Par conséquent, nous décidons de les utiliser comme des *jokers* ; elles sont comptés (toutes ou une partie d'elles) si elles permettent d'arriver à la condition $N_{ms} = N^{\mathcal{A}_{k-1,j}}$ (ligne 24-28 du pseudo-algorithme 5.4.3).

La faiblesse de notre approche est l'utilisation d'un seuil ($\pi/2$) implémenté en dur pour déterminer si deux pistes évoluent dans des directions opposées ou non. Par exemple, si la trajectoire des cibles du convoi comprend un virage de plus de 90° , notre méthode ne fonctionne pas. Une autre solution aurait été d'utiliser une technique de régression polynomiale d'ordre n telle que la courbe formée par les positions des cibles soit approximée par l'équation $y = \sum_{i=0}^n a_i x^i$ en choisissant n tel que l'erreur résiduelle soit inférieure à un certain seuil. Un exemple de cas limite illustre les avantages de cette approche avec la figure 5.8.




Fig. 5.8 – Étude des cas limites - (a) cas favorable - (b) cas défavorable

L'algorithme 5.4.3 décrit la technique utilisée.

Algorithme 5.4.3 Calcul du nombre de cibles évoluant dans le même sens

0: **Input :** $\{\mathcal{A}_{k-1,j}\}_{j=1}^{N^{\mathcal{A}}}$: ensemble des agrégats détectés et évalués à $k-1$
 $\hat{x}_{k-1}^{\mathcal{A}_i}$: barycentre de l'agrégat
 $P_{k-1}^{\mathcal{A}_i}$: covariance
 $N^{\mathcal{A}_i}$: nombre de cibles considérés dans l'agrégat
 $\{\hat{x}_{k,j}\}_{j=1}^{N^{\mathcal{A}}}$: ensemble des cibles appartenant à l'agrégat détecté
 α : seuil pour le fenêtrage statistique

- 1: Calcul du barycentre de l'agrégat détecté à k : $B = \frac{1}{N^{\mathcal{A}}} \sum_{j=1}^{N^{\mathcal{A}}} \hat{x}_{k,j}$
- 2: Initialisation : $N_{ms} = \text{zeros}(1, N^{\mathcal{A}})$
- 3: **for** $j = 1$ à $N^{\mathcal{A}}$ **do**

```

4:  Prédiction de l'état des agrégats précédent :  $\begin{cases} \hat{x}_{k|k-1}^{\mathcal{A}_i} = F \cdot \hat{x}_{k-1}^{\mathcal{A}_i} \\ P_{k|k-1}^{\mathcal{A}_i} = F \cdot P_{k-1}^{\mathcal{A}_i} \cdot F^T + Q \end{cases}$ 
5:  if test-statistique( $B, \hat{x}_{k|k-1}^{\mathcal{A}_i}, P_{k|k-1}^{\mathcal{A}_i}, \alpha$ ) then
6:       $sens = \text{zeros}(1, N^{\mathcal{A}})$ ,  $i = 1$ 
7:      while  $\|\hat{x}_{k,i+1}\| == 0$  do
8:           $i = i + 1$ 
9:      end while
10:      $sens(i) = 1$ 
11:     for  $l = i + 1$  à  $N^{\mathcal{A}}$  do
12:         if  $\|\hat{x}_{k,l-1}\| \neq 0$  then
13:              $sens = \text{init-sens}(sens)$ 
14:         end if
15:     end for
16:      $sens = \text{transfo-sens}(sens)$ 
17:      $id = \underset{\{\hat{x}_{k,i}\}_i \|\hat{x}_{k,i}\| == 0}{\text{argmin}} \quad d(\hat{x}_{k,i}, \hat{x}_{k-1}^{\mathcal{A}_i})$ 
18:     if  $\text{angle}(\hat{x}_{k,id}, \hat{x}_{k-1}^{\mathcal{A}_i}) < \pi/2$  &  $sens(id) == 2$  then
19:          $sens = \text{inv-sens}(sens)\{\textcircled{1}\}$ 
20:     end if
21:     if  $\text{angle}(\hat{x}_{k,id}, \hat{x}_{k-1}^{\mathcal{A}_i}) > \pi/2$  &  $sens(id) == 1$  then
22:          $sens = \text{inv-sens}(sens)\{\textcircled{2}\}$ 
23:     end if
24:     if  $|sens == 1| \leq N^{\mathcal{A}_j}$  &  $|sens == 1| + |sens == 0| \geq N^{\mathcal{A}_j}$  then
25:          $N_{ms}(l) = N^{\mathcal{A}_{k-1,j}}$ 
26:     else
27:          $N_{ms}(l) = |sens == 1| + |sens == 0|$ 
28:     end if
29: else if  $l == N^{\mathcal{A}}$  then
30:     if  $|sens == 1| \geq |sens == 2|$  then
31:          $N_{ms}(l + 1) = |sens == 1| + |sens == 0|$ 
32:     else
33:          $N_{ms}(l + 1) = |sens == 2| + |sens == 0|$ 
34:     end if
35:      $N^{\mathcal{A}_{k-1}, N^{\mathcal{A}+1}} = N_{ms}, \quad N^{\mathcal{A}} = N^{\mathcal{A}} + 1$ 
36: end if
37: end for
38: for all  $j \leq N^{\mathcal{A}}$  do
39:     if  $N^{\mathcal{A}_j} == N_{ms}(j)$  then
40:          $S_0^{\mathcal{A}_{k,j}} = 1$ 
41:     else
42:          $S_0^{\mathcal{A}_{k,j}} = 0$ 
43:     end if
44: end for

```

Output : $\left\{ S_0^{\mathcal{A}_{k,j}} \right\}_{j=1}^{N^{\mathcal{A}}}$: booléen indiquant si toutes les cibles vont dans le même sens

Conclusion

L'utilisation des fonctions de croyance permet de préciser l'état de connaissance d'un système. À l'initialisation, toutes les masses concernant les variables du système sont reportées sur le doute. Lorsque des informations sont disponibles, les masses sont reportées sur les hypothèses et le doute diminue. Par ailleurs, l'étude du conflit permet d'étudier la validité du modèle représentant le système. Finalement, il est possible d'étudier l'évolution temporelle du système ou de certaines de ces variables, par l'utilisation d'un filtre temporel crédibiliste. Le réseau crédibiliste est alors dit « dynamique ».

Nous avons appliqué ce formalisme au modèle convoi. Par ailleurs, nous avons proposé une amélioration dans sa modélisation. Les performances de ce nouvel outil dans le cadre de la détection de convoi seront analysées et comparées au modèle probabiliste dans le chapitre 7.

III

Résultats

Mesures de performance pour le pistage

Sommaire

6.1	Mesures de performance globale	156
6.1.1	Mesures calculées à chaque itération	156
6.1.2	Mesures moyennées sur le temps	156
6.2	Performances individuelles	157
6.3	Les nouvelles métriques	158
6.3.1	Distance de Wasserstein	159
6.3.2	Distance OSPA (Optimal SubPattern Assignment)	163
6.3.3	Un cas d'école	164

Dans le domaine du pistage multicible, faire une évaluation des performances revient à considérer plusieurs facteurs : capacité à évaluer le nombre exact de cibles évoluant sur la zone d'observation, précision de l'estimation de l'état des cibles (position, vitesse), robustesse aux fausses alarmes, capacité à gérer des cibles proches les unes des autres, capacité à assurer la continuité du pistage (ratio de longueur des pistes et taux de changement de pistes), etc. La discussion concernant le choix des mesures de performances reste par ailleurs complètement ouverte et fait l'objet de nombreuses publications [Rothrock 2000, Schuhmacher 2008]. À partir de ces différents paramètres d'évaluation, plusieurs mesures de performances (MOP : Measure Of Performances) peuvent être définies. Certaines MOP comme le ratio de fausses pistes permettent d'évaluer les performances de l'algorithme par rapport à un seul critère de performance (pour le ratio de fausses pistes, il s'agit d'évaluer la robustesse aux fausses alarmes), tandis que d'autres, comme la distance OSPA (Optimal SubPattern Assignment), permettent d'évaluer plusieurs critères en même temps. Ainsi, la distance OSPA évalue la précision de l'estimation de l'état des cibles, la précision de l'estimation du nombre de cibles ainsi que le taux de fausses alarmes.

L'utilisation des mesures de performances n'est possible que lorsque l'on dispose d'une vérité terrain fiable. C'est le cas avec des données simulées. Cependant, lors du traitement de données réelles, la vérité terrain peut être incomplète et imparfaite (désynchronisation des sources, biais spatial, ...). Il faut donc bien adapter le choix des MOP à la situation réelle, comme nous le ferons dans le chapitre 8 traitant des données réelles.

Trois types de MOP se distinguent parmi les MOP énumérés précédemment. Le premier type permet une évaluation globale des performances de pistage (*cf.* Partie 6.1). Le deuxième type évalue localement les performances individuelles des cibles (*cf.* Partie 6.2) et le troisième type de MOP, correspondant à de nouvelles métriques, permet de mesurer plusieurs critères de performances à la fois (6.3).

6.1 Mesures de performance globale

Pour évaluer les performances globales, il faut distinguer deux cas : les mesures que l'on peut calculer à chaque itération, et les mesures moyennées sur toute la durée de la simulation.

6.1.1 Mesures calculées à chaque itération

Les performances globales de pistage muticible sont présentées par l'intermédiaire de plusieurs indicateurs calculés à chaque itération :

La complétude : il s'agit du ratio entre le nombre de pistes valides (*i.e.* pistes décrivant effectivement la trajectoire d'une cible) obtenu par le système de détection et le nombre de cibles réelles issues de la vérité terrain. Elle tend idéalement vers la valeur 1.

Le ratio de fausses pistes : il s'agit du ratio entre le nombre de fausses pistes et le nombre de pistes valides. Il tend idéalement vers 0.

Le ratio de pistes redondantes : il s'agit du ratio entre le nombre de pistes valides et le nombre de cibles réelles associées à au moins une piste. Il tend idéalement vers 1.

En considérant ces trois premiers paramètres, une évaluation globale des capacités de pistage d'un algorithme est faite : capacité à pister l'ensemble des cibles mobiles, résistance aux fausses alarmes et redondance en présence de cibles proches. Cependant, il est également important de noter que les valeurs affichées sont relatives aux nombres de cibles mobiles à détecter. Ainsi, si le nombre de cibles est faible, les valeurs des taux de fausses pistes et taux de pistes redondantes peuvent paraître élevées alors qu'il n'y a pas pour autant beaucoup de fausses pistes ou beaucoup de pistes redondantes en terme de quantité.

D'autres indicateurs sont intéressants pour évaluer les performances de pistage :

La cardinalité : Nombre estimé de pistes par rapport au nombre de cibles réelles à chaque itération. Certains algorithmes comme le CPHD estime directement ce nombre, tandis que d'autres comme le MHT ne l'estime pas directement (dans ce cas, il est calculé comme le nombre de pistes confirmées).

Ce paramètre permet d'évaluer la capacité des algorithmes à estimer le nombre de cibles sans confondre avec les capacités de labellisation des pistes, c'est à dire la capacité à associer correctement les pistes aux cibles existantes.

6.1.2 Mesures moyennées sur le temps

Deux autres paramètres, dont les valeurs sont moyennées dans le temps, permettent d'évaluer les capacités de pistage des cibles individuelles.

Le ratio de longueur des pistes : il s'agit, pour chaque cible, de déterminer le ratio entre la longueur estimée des pistes décrivant une cible sur la longueur réelle de la durée de perception (*cf.* §6.2) de cette cible.

Les ARMSE (Average Root Mean Square Error) position et vitesse : il s'agit de l'erreur en position et vitesse par rapport à la vérité terrain moyennée pour chaque cible ou moyennées sur l'ensemble des cibles.

Ces deux paramètres permettent d'évaluer les capacités à pister une cible particulière. Cependant, ces MOP deviennent de moins en moins interprétables lorsque le nombre de cibles augmente.

6.2 Performances individuelles

À présent, nous décrivons les MOP associées à une cible i particulière. On distingue principalement cinq indicateurs de performance qui sont :

La perception : Il s'agit d'un indicateur booléen indiquant à chaque itération si une cible est détectée ou non. Par ailleurs, pour être détectable, la cible doit être dans la zone d'observation d'un capteur et avoir une vitesse supérieure à la vitesse minimum de détection. Finalement, l'indicateur est égal à 1 si une mesure peut être associée à la cible. La détectabilité n'a de sens que lorsqu'on étudie les performances d'un seul jeu de mesures (typiquement avec des données réelles), cependant dans ce cas, les mesures ne sont pas labellisées et on ignore leur provenance. Pour les performances moyennées sur plusieurs jeux de Monte-Carlo, la détectabilité n'est pas pertinente, puisque moyennée, et la valeur moyenne tend logiquement vers la probabilité de détection du capteur.

Le RMSE en position : L'erreur moyenne en position au sens des moindres carrés notée $e_{k,i}^{pos}$ ou Root Mean Square Error (RMSE) d'une cible i à l'itération k se calcule en moyennant l'erreur entre la position réelle d'une cible $(x_{k,i}, y_{k,i})$ et sa position estimée $(\hat{x}_{k,i}^n, \hat{y}_{k,i}^n)$ (si la cible est détectée par l'algorithme avec le jeu de mesures n), telle que :

$$e_{k,i}^{pos} = \sqrt{\frac{1}{N_{k,i}^{MC}} \sum_{n=1}^{N_{k,i}^{MC}} \left\{ \begin{array}{l} \left((x_{k,i} - \hat{x}_{k,i}^n)^2 + (y_{k,i} - \hat{y}_{k,i}^n)^2 \right) \\ 0 \end{array} \right. \begin{array}{l} \text{si il existe une estimation} \\ \text{sinon} \end{array}} \quad (6.1)$$

où N_{MC} est le nombre de jeux de Monte-Carlo effectués, $N_{k,i}^{MC}$ est le nombre de jeux de Monte-Carlo à l'itération k où la cible i est associée à une piste et les vecteurs $(x_{k,i}, y_{k,i})$ et $(\hat{x}_{k,i}^n, \hat{y}_{k,i}^n)$ représentent les positions réelles et estimées de la cible i à l'itération k avec le jeu de mesures n .

Le RMSE en vitesse : De même que pour l'équation (6.1), l'erreur moyenne quadratique en vitesse est calculée de la façon suivante

$$e_{k,i}^{vit} = \sqrt{\frac{1}{N_{k,i}^{MC}} \sum_{n=1}^{N_{k,i}^{MC}} \left\{ \begin{array}{l} \left((\dot{x}_{k,i} - \hat{\dot{x}}_{k,i}^n)^2 + (\dot{y}_{k,i} - \hat{\dot{y}}_{k,i}^n)^2 \right) \\ 0 \end{array} \right. \begin{array}{l} \text{si il existe une estimation} \\ \text{sinon} \end{array}} \quad (6.2)$$

avec les vecteurs $(\dot{x}_{k,i}, \dot{y}_{k,i})$ et $(\hat{\dot{x}}_{k,i}, \hat{\dot{y}}_{k,i})$ représentant les vitesses réelles et estimées de la cible i à l'itération k .

La continuité de pistage : La continuité de pistage d'une cible i est une mesure qui permet de suivre les interruptions dans l'association d'une piste à une cible réelle i . Si à une cible i à l'itération k $x_{k,i}$ peut être associée une estimation $\hat{x}_{k,i}^n$ alors la continuité de pistage est assurée et la continuité pour le jeu de mesure n , $\iota_{k,i}^n$ est égale

à 1 (elle est égale à 0 sinon). Finalement, les résultats sont moyennés sur l'ensemble des jeux de Monte-Carlo tel que :

$$\bar{\nu}_{k,i} = \frac{1}{N^{MC}} \sum_{n=1}^{N^{MC}} \nu_{k,i}^n \quad (6.3)$$

Le taux de changement de pistes : Un dernier enjeu dans le cadre du pistage multicible est de réussir à associer une cible à une seule piste. Il égal à 1 dès qu'une cible est associée à une nouvelle piste. Par conséquent, le taux de changement de piste $\bar{\nu}_{k,i}$ d'une cible i est défini tel que $\bar{\nu}_{k,i}^n = 1$ si une cible i est associée à une piste λ_1 à l'itération $k - 1$ et à une piste λ_2 à l'itération k ou si la cible n'était associée à aucune piste à l'itération $k - 1$. Il est égal à 0 sinon. Finalement, les résultats sont moyennés sur l'ensemble des jeux de Monte-Carlo tel que :

$$\bar{\nu}_{k,i} = \frac{1}{N^{MC}} \sum_{n=1}^{N^{MC}} \nu_{k,i}^n \quad (6.4)$$

L'ensemble de ces critères (globaux et individuels) permet d'avoir un aperçu complet des capacités de pistage multicible : capacité à évaluer de façon correcte le nombre de cibles sur la zone d'observation et à créer les bonnes associations, robustesse par rapport aux fausses alarmes et capacité à discriminer les cibles proches. Cependant, représenter chaque aspect des performances par une mesure de performance particulière n'est pas toujours lisible. C'est pourquoi, les auteurs, en particulier Hoffman et Mahler [Hoffman 2002, Hoffman 2004], se sont intéressés à de nouvelles métriques qui prennent en compte plusieurs aspects des performances pour faire apparaître, avec une seule métrique la supériorité ou non d'un algorithme.

6.3 Les nouvelles métriques

La figure 6.1 illustre la problématique d'évaluation des performances dans un contexte multicible.

Nous présentons ici quatre cas de figures différents : cas optimal, piste redondante, piste manquante et fausse piste. La première question que nous pouvons nous poser est : « Y a-t'il réellement un cas plus favorable (*i.e.* plus proche de la réalité) qu'un autre (hormis le cas optimal) ? » Et finalement, par cette question, nous comprenons qu'on ne peut pas définir un cas comme meilleur qu'un autre mais cependant, un cas peut être plus favorable qu'un autre par rapport à une certaine problématique (robustesse par rapport aux fausses alarmes) et une mesure de performance sera performante si elle est capable de mettre en valeur cette problématique : la qualité d'une estimation est toujours définie par rapport un critère qu'il n'est pas évident de définir. Par ailleurs, nous conseillons, sur le sujet, la lecture du chapitre 4 de [Vo 2008].

Ainsi, depuis 2002, la distance de Wasserstein [Hoffman 2004] et la distance OSPA (Optimal SubPattern Assignment) [Schuhmacher 2008] sont utilisées comme référence dans les publications traitant du pistage multicible. Globalement, la distance de Wasserstein (*cf.* §6.3.1) est une mesure de distance entre deux espaces qui n'ont pas la même cardinalité et qui pénalise les différences de cardinalité. La distance OSPA, sur le même principe,

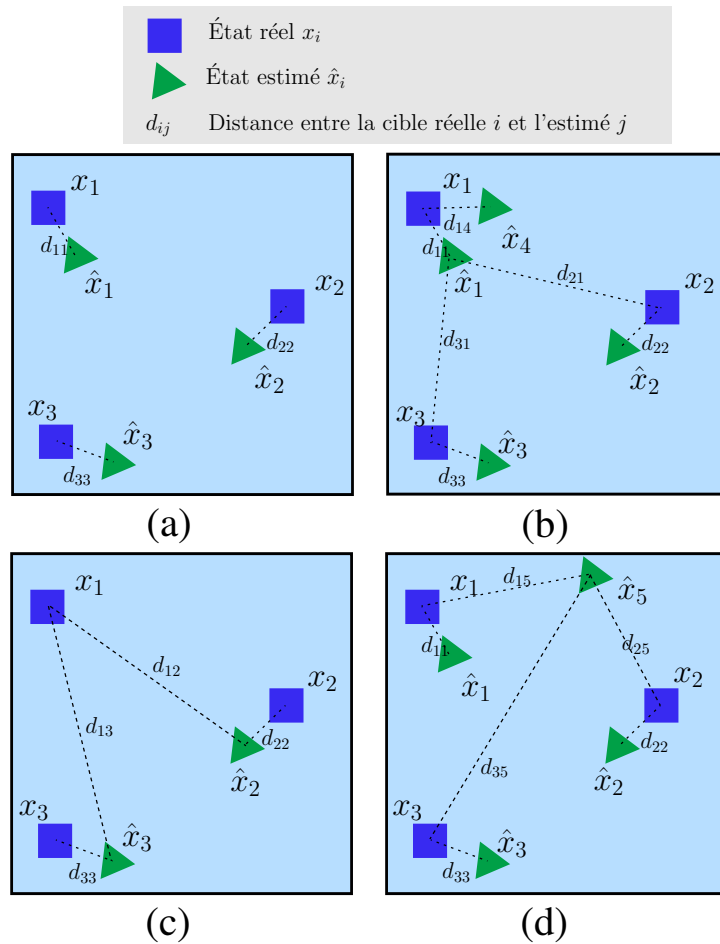


Fig. 6.1 – Illustration du problème de calcul de performances dans un cas multicible - (a) Cas idéal - (b) Piste redondante (\hat{x}_1, \hat{x}_4) - (c) Piste manquante (x_1) - (d) Fausse piste (\hat{x}_5)

permet de fournir une mesure entre deux espaces qui n'ont pas nécessairement la même cardinalité, en pondérant plus ou moins la différence de cardinalité, l'erreur en position ou la quantité de fausses pistes comme cela sera montré dans le paragraphe 6.3.2.

6.3.1 Distance de Wasserstein

6.3.1.1 Rappels théoriques

Considérons le vecteur de dimension n , $\mathbf{x} = \{x_1, \dots, x_n\}$ tels que \mathbf{x} appartienne à \mathbb{R}^n

La longueur du vecteur est traditionnellement donnée par la norme Euclidienne (norme \mathcal{L}^2) qui est définie comme :

$$\|\mathbf{x}\|_2 = (x_1^2 + \dots + x_n^2)^{(1/2)} \tag{6.5}$$

Cependant, d'autres métriques existent, il est possible de définir la norme de \mathbf{x} au sens de \mathcal{L}^p (eq. (6.6)), voire de \mathcal{L}^∞ (eq. (6.7)) :

$$\|\mathbf{x}\|_p = (|x_1|^p + \dots + |x_n|^p)^{(1/p)} \tag{6.6}$$

$$\|\mathbf{x}\|_\infty = \max(|x_1|, \dots, |x_n|) \quad (6.7)$$

6.3.1.2 Définition de la distance de Wasserstein

Maintenant, considérons deux vecteurs de dimensions n et m pas nécessairement égales, tels que $\mathbf{x} = \{x_1, \dots, x_n\}$ et $\mathbf{y} = \{y_1, \dots, y_m\}$ appartiennent à \mathbb{R}^n et \mathbb{R}^m . Nous sommes capables, de la même façon qu'en (6.6) et (6.7), de définir la distance entre ces deux vecteurs s'ils sont de même dimension n et tel que $d(x_i, y_i) = |x_i - y_i|$:

$$d^p(\mathbf{x}, \mathbf{y}) = \left(\sum_{i=1}^n d(x_i, y_i) \right) \quad (6.8)$$

$$d^\infty(\mathbf{x}, \mathbf{y}) = \max_{1 \leq i \leq n} (d(x_i, y_i)) \quad (6.9)$$

Cependant, ces distances n'ont un sens que si l'on est capable d'assigner les x_i et les y_i correctement. Ainsi, on cherche à minimiser la distance totale et on cherche donc la combinaison d'association des x_i aux y_i qui minimise cette distance. Si $n > m$, on choisit les m associations des x_i aux y_i et si $m > n$, on choisit les n associations des y_i aux x_i (les $n - m$ ou $m - n$ éléments restants ne sont associés à rien). Finalement, la distance de Wasserstein entre \mathbf{x} et \mathbf{y} , notée $d_p^W(\mathbf{x}, \mathbf{y})$ au sens de la norme \mathcal{L}^p s'écrit :

$$d_p^W(\mathbf{x}, \mathbf{y}) = \operatorname{argmin}_U \left(\sum_{i=1}^{|\mathbf{x}|} \sum_{j=1}^{|\mathbf{y}|} U_{i,j} \|x_i - y_j\| \right) \quad (6.10)$$

où U est appelée, matrice de transfert de l'ensemble \mathbf{x} à l'ensemble \mathbf{y} , de taille $|\mathbf{x}| \times |\mathbf{y}|$, $U_{i,j}$ est l'élément de la i^{me} ligne et de la j^{me} colonne et \mathcal{U} représente l'ensemble des matrices de transfert possibles.

De plus, la matrice U doit satisfaire les conditions suivantes :

$$\begin{cases} \forall i \leq |\mathbf{x}|, \forall j \leq |\mathbf{y}|, U_{i,j} \geq 0 \\ \forall i \leq |\mathbf{x}|, \sum_{j=1}^{|\mathbf{y}|} U_{i,j} = \frac{1}{|\mathbf{x}|} \\ \forall j \leq |\mathbf{y}|, \sum_{i=1}^{|\mathbf{x}|} U_{i,j} = \frac{1}{|\mathbf{y}|} \end{cases} \quad (6.11)$$

La deuxième (*resp.* troisième) condition équivaut à ce que la somme des lignes (*resp.* colonnes) de la matrice soit égal à l'inverse du nombre de lignes (*resp.* colonnes).

Prenons par exemple, le cas où $|\mathbf{x}| > |\mathbf{y}|$, imaginons que les $|\mathbf{y}|$ premiers éléments de \mathbf{x} soient triés et associés respectivement aux éléments de la matrice de transfert tel que x_i est associé à y_i et que les $(|\mathbf{x}| - |\mathbf{y}|)$ éléments restants correspondent à des fausses pistes. Alors, la matrice U s'écrit :

$$U = \begin{bmatrix} \frac{1}{|\mathbf{y}|} & 0 & \dots & 0 & \frac{1}{|\mathbf{y}| \times |\mathbf{x}|} & \dots & \frac{1}{|\mathbf{y}| \times |\mathbf{x}|} \\ 0 & \frac{1}{|\mathbf{y}|} & \ddots & \vdots & \frac{1}{|\mathbf{y}| \times |\mathbf{x}|} & \dots & \frac{1}{|\mathbf{y}| \times |\mathbf{x}|} \\ \vdots & \ddots & \ddots & 0 & \dots & \dots & \vdots \\ 0 & \dots & 0 & \frac{1}{|\mathbf{y}|} & \frac{1}{|\mathbf{y}| \times |\mathbf{x}|} & \dots & \frac{1}{|\mathbf{y}| \times |\mathbf{x}|} \end{bmatrix} \quad (6.12)$$

Et finalement, la distance de Wasserstein $d_p^W(\mathbf{x}, \mathbf{y})^{(a)}$ est égale à la distance moyenne entre les objets réels et leur estimé respectif :

$$d_p^W(\mathbf{x}, \mathbf{y})^{(a)} = \frac{1}{3} (d_{11} + d_{22} + d_{33}) \quad (6.15)$$

Cas (b) : Ce cas correspond au cas où l'état estimé \hat{x}_4 est redondant avec l'état estimé \hat{x}_1 . On a $\mathbf{x} = \{\hat{x}_1, \hat{x}_2, \hat{x}_3, \hat{x}_4\}$ et $\mathbf{y} = \{x_1, x_2, x_3\}$. La matrice de transfert est la suivante :

$$U = \begin{bmatrix} 1/4 & 0 & 0 & 1/12 \\ 0 & 1/4 & 0 & 1/12 \\ 0 & 0 & 1/4 & 1/12 \end{bmatrix} \quad (6.16)$$

Finalement, la distance de Wasserstein associée $d_p^W(\mathbf{x}, \mathbf{y})^{(b)}$ équivaut à trois quarts de la distance moyenne entre les objets réels et leur estimé respectif. Le quatrième quart pénalise l'erreur de cardinalité et est égale à un quart de la distance moyenne entre l'estimé redondant et tous les objets réels. Soit :

$$d_p^W(\mathbf{x}, \mathbf{y})^{(b)} = \frac{1}{4} (d_{14} + d_{22} + d_{33}) + \frac{1}{12} (d_{11} + d_{21} + d_{31}) \quad (6.17)$$

Et on a :

$$d_p^W(\mathbf{x}, \mathbf{y})^{(b)} > d_p^W(\mathbf{x}, \mathbf{y})^{(a)} \quad (6.18)$$

Cas (c) : Il s'agit du cas où l'objet 1 n'est pas détecté. On a $\mathbf{x} = \{\hat{x}_1, \hat{x}_2\}$ et $\mathbf{y} = \{x_1, x_2, x_3\}$. La matrice de transfert est la suivante :

$$U = \begin{bmatrix} 1/3 & 0 \\ 0 & 1/3 \\ 1/6 & 1/6 \end{bmatrix} \quad (6.19)$$

Finalement, la distance de Wasserstein $d_p^W(\mathbf{x}, \mathbf{y})^{(c)}$ associée au cas (c) correspond aux deux tiers de la distance moyenne entre les deux objets correctement associés et un tiers de la distance moyenne entre l'objet non associé et les deux états estimés, tel que :

$$d_p^W(\mathbf{x}, \mathbf{y})^{(c)} = \frac{1}{3} (d_{22} + d_{33}) + \frac{1}{6} (d_{12} + d_{13}) \quad (6.20)$$

Comme la pénalité compte ici pour un tiers de la distance, alors qu'elle comptait pour un quart dans le cas (b), on a finalement :

$$d_p^W(\mathbf{x}, \mathbf{y})^{(c)} > d_p^W(\mathbf{x}, \mathbf{y})^{(b)} \quad (6.21)$$

Cas (d) : Ce dernier cas correspond à la présence d'une fausse piste. On a $\mathbf{x} = \{\hat{x}_1, \hat{x}_2, \hat{x}_3, \hat{x}_4\}$ et $\mathbf{y} = \{x_1, x_2, x_3\}$. La matrice de transfert est la suivante :

$$U = \begin{bmatrix} 1/3 & 0 \\ 0 & 1/3 \\ 1/6 & 1/6 \end{bmatrix} \quad (6.22)$$

On en déduit la distance de Wasserstein correspondante qui est très similaire à celle correspondant au cas (b) :

$$d_p^W(\mathbf{x}, \mathbf{y})^{(b)} = \frac{1}{4} (d_{11} + d_{22} + d_{33}) + \frac{1}{12} (d_{15} + d_{25} + d_{35}) \quad (6.23)$$

Contrairement au cas (b) où d_{11} est une faible distance alors que les deux autres distances sont grandes, ici, toutes les distances liées à la fausse piste d_{15} , d_{25} et d_{35} , sont grandes et on a finalement :

$$d_p^W(\mathbf{x}, \mathbf{y})^{(d)} > d_p^W(\mathbf{x}, \mathbf{y})^{(b)} \quad (6.24)$$

6.3.2 Distance OSPA (Optimal SubPattern Assignment)

6.3.2.1 Définition

Une nouvelle métrique appelée distance OSPA (Optimal Subpattern Assignment) a été proposée pour soulever les contraintes liées à la distance de Wasserstein présentées dans la partie 6.3.1.3. Par ailleurs la distance OSPA offre un formalisme mathématique plus intuitif et rigoureux. Cette métrique dépend de deux paramètres : p et c . Le paramètre p représente la sensibilité de la métrique aux fausses pistes. Le paramètre c représente la pénalité accordée aux erreurs sur le nombre de cibles estimé ainsi que les erreurs de localisation. Avant de calculer la métrique, de même que pour la distance de Wasserstein où il fallait calculer la matrice de transfert U , il faut calculer l'ensemble d'associations Π qui minimise la distance entre les éléments de l'ensemble ayant la plus petite cardinalité aux éléments de l'autre ensemble. Par conséquent, cet ensemble est de taille la cardinalité de l'ensemble le plus grand. Si $\Pi(i) = j$, alors le $i^{\text{ème}}$ élément de l'ensemble le plus grand est associé au $j^{\text{ème}}$ élément de l'ensemble le plus petit. Finalement, si $\Pi(i) = 0$, le $i^{\text{ème}}$ élément de l'ensemble le plus grand n'est associé à rien.

Pour finir, la distance OSPA entre deux ensembles $\mathbf{x} = \{x_1, \dots, x_n\}$ et $\mathbf{y} = \{y_1, \dots, y_m\}$ appartenant à \mathbb{R}^n et \mathbb{R}^m s'écrit :

$$\bar{d}_p^{(c)}(\mathbf{x}, \mathbf{y}) = \begin{cases} \left(\frac{1}{n} \left(\min_{\pi \in \Pi_n} \sum_{i=1}^m d^{(c)}(x_i, y_{\pi(i)})^p + c^p(n-m) \right) \right)^{\frac{1}{p}} & \text{si } m \leq n \\ \bar{d}_p^{(c)}(\mathbf{y}, \mathbf{x}) & \text{si } m > n \end{cases} \quad (6.25)$$

où $d^{(c)}(x, y)$ est la distance minimale entre la distance effective entre x et y et la distance maximale considérée correspondant au paramètre c :

$$d^{(c)}(x_i, y_j) = \min(c, |x_i - y_j|) \quad (6.26)$$

6.3.2.2 Implémentations

Nous allons à présent décrire l'implémentation de la distance OSPA pour les cas présentés sur la figure 6.1 :

Cas (a) : Pour le cas idéal, le vecteur d'association est le suivant :

$$\Pi = [1 \ 2 \ 3] \quad (6.27)$$

Et finalement, la distance OSPA :

$$\bar{d}_p^{(c)}(\mathbf{x}, \mathbf{y})^{(a)} = \frac{1}{3} (d_{11} + d_{22} + d_{33}) \quad (6.28)$$

Et on remarque que :

$$\bar{d}_p^{(c)}(\mathbf{x}, \mathbf{y})^{(a)} = d_p^W(\mathbf{x}, \mathbf{y})^{(a)} \quad (6.29)$$

Cas (b) : Le vecteur d'association est le suivant :

$$\Pi = [0 \ 2 \ 3 \ 1] \quad (6.30)$$

On en déduit la distance OSPA :

$$\bar{d}_p^{(c)}(\mathbf{x}, \mathbf{y})^{(b)} = \frac{1}{4} ((d_{14} + d_{22} + d_{33})^p + c^p)^{1/p} \quad (6.31)$$

Et pour $p = 2$, on a donc :

$$\begin{aligned} \bar{d}_2^{(c)}(\mathbf{x}, \mathbf{y})^{(b)} &\geq d_2^W(\mathbf{x}, \mathbf{y})^{(b)} && \text{si } c \geq \frac{1}{3} (d_{11} + d_{21} + d_{31}) \\ \bar{d}_2^{(c)}(\mathbf{x}, \mathbf{y})^{(b)} &< d_2^W(\mathbf{x}, \mathbf{y})^{(a)} && \text{sinon} \end{aligned} \quad (6.32)$$

Cas (c) : Le vecteur d'association est le suivant :

$$\Pi = [0 \ 2 \ 3] \quad (6.33)$$

On en déduit la distance OSPA :

$$\bar{d}_p^{(c)}(\mathbf{x}, \mathbf{y})^{(b)} = \frac{1}{3} ((d_{22} + d_{33})^p + c^p)^{1/p} \quad (6.34)$$

Et de même que pour le cas (b), on obtient la relation suivante :

$$\begin{aligned} \bar{d}_2^{(c)}(\mathbf{x}, \mathbf{y})^{(c)} &\geq d_2^W(\mathbf{x}, \mathbf{y})^{(c)} && \text{si } c \geq \frac{1}{2} (d_{12} + d_{13}) \\ \bar{d}_2^{(c)}(\mathbf{x}, \mathbf{y})^{(c)} &< d_2^W(\mathbf{x}, \mathbf{y})^{(c)} && \text{sinon} \end{aligned} \quad (6.35)$$

Cas (d) : Le vecteur d'association est le suivant :

$$\Pi = [1 \ 2 \ 3 \ 0] \quad (6.36)$$

On en déduit la distance OSPA :

$$\bar{d}_p^{(c)}(\mathbf{x}, \mathbf{y})^{(b)} = \frac{1}{4} ((d_{11} + d_{22} + d_{33})^p + c^p)^{1/p} \quad (6.37)$$

On remarque alors que

$$\bar{d}_p^{(c)}(\mathbf{x}, \mathbf{y})^{(d)} = \bar{d}_p^{(c)}(\mathbf{x}, \mathbf{y})^{(b)} \quad (6.38)$$

Dans le cas défavorable présenté sur la figure 6.2, la distance OSPA traduit bien la mauvaise estimation de la situation faite par l'algorithme. Ainsi, pour $c = 100$ et $p = 2$:

$$\bar{d}_2^{(c)}(\mathbf{x}, \mathbf{y}) = \frac{1}{30} \left((1 + 1 + 1 + 1 + 1)^2 + 100^2 \cdot (30 - 5) \right)^{1/2} = 158 \quad (6.39)$$

6.3.3 Un cas d'école

Avant de conclure sur ce chapitre, nous allons présenter un cas d'école (*cf.* Figure 6.3), évaluable intuitivement, où la supériorité de la distance OSPA apparaît par rapport à la distance de Wasserstein.

Pour les calculs qui vont suivre, la distance entre l'objet et ses estimés respectifs est de 1, tandis que la distance entre les deux objets est de 200. On utilise les paramètres $p = 1$ et $c = 200$.




Fig. 6.3 – **Un cas d'école** - \circ *Etats réels* - λ *Etats estimés*

Cas (a) : un seul objet possède deux états estimés. La distance de Wasserstein ne pénalise pas la redondance, puisque la matrice de transfert est la suivante :

$$U^{(a)} = [1/2 \quad 1/2] \quad (6.40)$$

Et ainsi, on obtient :

$$d^W(\mathbf{x}, \mathbf{y})^{(a)} = 1 \quad (6.41)$$

Tandis que la distance OSPA est égale à $\bar{d}(\mathbf{x}, \mathbf{y})^{(a)} = 101$.

Cas (b) : on a deux objets bien détectés et une piste redondante. Intuitivement, le cas (b) est plus favorable que le cas (a). Pourtant, la distance de Wasserstein est plus grande pour le cas (a) que pour le cas (b). Elle se calcule grâce à la matrice de transfert suivante :

$$U^{(b)} = \begin{bmatrix} 1/3 & 0 & 1/6 \\ 0 & 1/3 & 1/6 \end{bmatrix} \quad (6.42)$$

Et finalement, on obtient :

$$d^W(\mathbf{x}, \mathbf{y})^{(b)} = \frac{1}{3} \cdot 1 + \frac{1}{3} \cdot 1 + \frac{1}{6} \cdot 1 + \frac{1}{6} \cdot 200 = 67 \quad (6.43)$$

Tandis que la distance OSPA est la suivante :

$$\bar{d}(\mathbf{x}, \mathbf{y})^{(b)} = \frac{1}{3} \cdot ((1 + 1) + 200) = 67 \quad (6.44)$$

Cas (c) : On a deux objets bien détectés et chaque objet a une piste redondante. Le cas (c) représente une moins bonne estimation de la réalité que le cas (b). Ceci n'est pas reflété par le calcul de la distance de Wasserstein avec :

$$U^{(c)} = \begin{bmatrix} 1/4 & 0 & 1/4 & 0 \\ 0 & 1/4 & 0 & 1/4 \end{bmatrix} \quad (6.45)$$

Et finalement :

$$d^W(\mathbf{x}, \mathbf{y})^{(c)} = \frac{1}{4} \cdot 1 + \frac{1}{4} \cdot 1 + \frac{1}{4} \cdot 1 + \frac{1}{4} \cdot 1 = 1 \quad (6.46)$$

Tandis que la distance OSPA est elle plus grande pour le cas (c) que pour le cas (b) avec :

$$\bar{d}(\mathbf{x}, \mathbf{y})^{(c)} = \frac{1}{4} \cdot ((1 + 1) + 2 \cdot 200) = 101 \quad (6.47)$$

Conclusion

Dans cette partie, nous avons décrit un certain nombre de mesures de performances : des performances globales et locales ainsi que des performances mélangeant les deux. Nous avons montré leurs avantages et leurs limites. Concernant les nouvelles métriques développées par Hoffman et Mahler, si la distance de Wasserstein souffre de certaines déficiences, la métrique OSPA quant à elle fournit une bonne évaluation de la situation et a l'avantage de pouvoir pondérer les fausses pistes ainsi que l'estimation de l'état et du nombre de cibles.

Dans les chapitres suivants, nous allons utiliser ces métriques afin d'évaluer notre algorithme de pistage multicible avec des données simulées et des données réelles.

Résultats sur données simulées

Sommaire

7.1 Paramètres de simulation	168
7.1.1 Paramètres du capteur GMTI	168
7.1.2 Paramètres du filtre GM-CPHD	168
7.1.3 Paramètres de l'IMM-MHT	169
7.1.4 Paramètres de l'hybridation	169
7.1.5 Paramètres de détection de l'agrégat	170
7.1.6 Paramètres de transformation des données en probabilités	170
7.1.7 Paramètres de calcul des MOP	172
7.2 Scénario 1 : basique	173
7.2.1 Description du scénario 1	173
7.2.2 Résultats du scénario 1	175
7.3 Scénario 2 : dépassement d'un convoi	185
7.3.1 Résultats du pistage pour le scénario 2	185
7.3.2 Résultats pour la détection de convois pour le scénario 2	194
7.3.3 Bilan	196
7.4 Scénario 3 : complexe	198
7.4.1 Description du scénario 3	198
7.4.2 Résultats du scénario 3 pour la détection de convois	200
7.4.3 Résultats pour la détection de convois pour le scénario 3	211
7.4.4 Bilan sur le scénario 3	216
7.5 Scénario 4 : manœuvre intrinsèque dans un convoi	219
7.5.1 Description du scénario 4	219
7.5.2 Résultat du pistage	221
7.5.3 Résultat pour la détection de convoi	222
7.6 Influence des paramètres	226
7.6.1 Nombre de cibles dans le convoi	226
7.6.2 Distance entre les cibles	227
7.6.3 Densité de fausses alarmes	229
7.6.4 Bruit de mesures	230
7.6.5 Paramètres de transformation des données en probabilités	231
7.6.6 Paramètres d'estimation du nombre de cibles	232

Introduction

Dans la partie I, nous avons élaboré un nouvel algorithme de pistage multicible qui améliore les performances de pistage des cibles proches. Nous allons donc comparer les

performances de pistage pour plusieurs scénarios simples ou complexes afin de mettre en valeur les caractéristiques de notre algorithme.

Par ailleurs, dans la deuxième partie, nous avons décrit une méthode pour la détection de convoi. Nous avons développé deux approches pour cette méthode : une première approche probabiliste et une deuxième approche crédibiliste. Nous allons décrire les résultats obtenus pour la détection de convoi et comparer les différences obtenues avec ces deux approches. Tous les résultats sont calculés grâce à l'utilisation d'un simulateur de données GMTI fonctionnant sous *Matlab*.

Dans ce chapitre, nous commençons dans la partie 7.1 par décrire tous les paramètres utilisés pour nos simulations (paramètres des capteurs, paramètres des filtres, paramètres de détection de convoi et paramètres pour le calcul des performances). Ensuite, nous décrivons et interprétons les résultats obtenus pour quatre scénarios des plus simples aux plus complexes. Le scénario 1 (Partie 7.2) est un scénario très simple pour comparer les performances de pistage multicible. Le scénario 2 (Partie 7.3) fait intervenir un convoi et une cible individuelle pour tester la capacité de détection du module de détection de convoi. Finalement, les scénarios 3 et 4 (Partie 7.4 et 7.5) font intervenir des manœuvres intrinsèques et extrinsèques pour les convois afin de tester de manière plus réaliste les performances de détection et d'évaluation de convois. Finalement, dans une dernière partie (Partie 7.6), nous faisons varier les différents paramètres pour étudier les limites des approches développées.

7.1 Paramètres de simulation

Dans cette première partie, nous décrivons les jeux de paramètres concernant, les caractéristiques des capteurs, les paramètres des filtres et ceux concernant la détection de convois. Nous serons amenés, au cours de ce chapitre, à faire varier ponctuellement certains paramètres (densité de fausses alarmes, bruit sur les mesures, ...) afin d'étudier leur influence sur les performances de pistage. Cependant, par défaut, nous utilisons les paramètres qui sont énumérés ci-dessous.

7.1.1 Paramètres du capteur GMTI

Comme décrit dans la partie 1.2.3.2, le capteur GMTI est un capteur aéroporté caractérisé par sa position par rapport à la zone d'observation, par son emprise rectangulaire capteur où, à chaque instant d'acquisition, un ensemble de plots Z_k correspondant aux positions des cibles mobiles est détecté. Au delà des paramètres d'acquisition, le capteur est caractérisé par un certain nombre de paramètres intrinsèques (bruit sur les mesures, densité de fausses alarmes, ...), dont vont dépendre la précision des mesures. Dans ce chapitre, nous simulons une emprise capteur fixe ; de plus, nous supposons que la trajectoire du porteur est rectiligne et sa vitesse constante. L'ensemble de ces paramètres est décrit dans le tableau 7.1.

7.1.2 Paramètres du filtre GM-CPHD

Les paramètres utiles pour la mise en œuvre du filtre GM-CPHD sont nombreux comme on le comprend dans la description de l'algorithme (Partie 2.3). Si certains critères comme les nombres maximaux de cibles et de gaussiennes considérées peuvent être simplement établis (par ailleurs, leur ajustement sert à limiter la combinatoire), d'autres critères comme

Nom	Valeur	Notation
Bruit en distance	20 m	σ_r
Bruit en azimut	8.10^{-4} rad	σ_ϕ
Probabilité de détection	0.9	P_d
Densité de F.A.	$8.92.10^{-8}$	β_{fa}
Vitesse minimale de détection	1 m.s^{-1}	v_{min}
Période d'échantillonnage	10 s	Δ
Vitesse du capteur	30 m.s^{-1}	v^{mti}
Altitude du capteur	4000 m	Z^{mti}
Zone d'observation	9 km^2	V_k

Tab. 7.1 – Paramètres du capteur GMTI

le bruit de modèle, le nombre moyen de cibles naissantes ou le poids initial des gaussiennes sont moins intuitifs. Après test sur de nombreux scénarios avec des plages de valeurs différentes pour ces paramètres (nos plages de valeur pour les paramètres sont décrites dans [Pollard 2008b]), nous avons abouti aux paramètres décrits dans le tableau 7.2. Le paramètre le plus critique à établir est le bruit de modèle q^{PHD} , car ce dernier dépend, entre autre, de la distance du capteur à la scène et des bruits de mesure. Dans nos simulations, la distance et les bruits restent à peu près les mêmes, donc ce paramètre ne nécessite pas d'ajustement. Cependant, avec les données réelles, nous verrons comment l'ajuster.

Nom	Valeur	Notation
Probabilité de fenêtrage	0.99	P_g
Probabilité de survie	0.98	P_s
Poids initial des gaussiennes	10^{-3}	w_0
Seuil pour le pruning	10^{-2}	U_1
Seuil pour le merging	20	U_2
Nombre maximal de cibles considérés	50	N_{max}
Nombre maximal de gaussiennes considérées	50	J_{max}
Nombre moyen de cibles naissantes	0.06	n_{nt}
Bruit de modèle	2 m.s^{-2}	q^{PHD}
Vitesse maximale des cibles	20 m.s^{-1}	v_{max}

Tab. 7.2 – Paramètres du filtre GM-CPHD

7.1.3 Paramètres de l'IMM-MHT

La gestion de l'arbre d'hypothèses d'association du MHT implique le choix d'un certain nombre de paramètres décrits dans le tableau 7.3. Par ailleurs, l'utilisation d'un IMM implique un choix pour les caractéristiques des modèles utilisés (tableau 7.4). Les variables décrites ici n'ont pas forcément été utilisées auparavant. Nous invitons le lecteur à se référer aux travaux de Benjamin Pannetier [Pannetier 2006a] pour plus de détails.

7.1.4 Paramètres de l'hybridation

Les paramètres de l'hybridation et de la labellisation du filtre GM-CPHD sont décrits dans le tableau 7.5. En effet, en pratique le score n'est pas calculé sur toute la durée de

Nom	Valeur	Notation
Densité de nouvelles cibles	$8.92 \cdot 10^{-9}$	β_{nt}
Seuil de confirmation de piste	10^{-4}	γ_1
Seuil de suppression de piste	10^{-1}	γ_2
Seuil de suppression des hypothèses	10^{-2}	γ_3
Nombre de branches à conserver	2	N_{bran}
Seuil de probabilité globale d'une piste	0.1	γ_4
Nombres de <i>scan</i> avant <i>pruning</i>	3	N_{prun}
Probabilité de fenêtrage	0.95	P_g

Tab. 7.3 – Paramètres du filtre MHT

Nom	Valeur	Notation
Bruit pour le modèle CV1	0.05	q^{M_1}
Bruit pour le modèle CV2	0.8	q^{M_2}
Matrice de transition des modèles	$\begin{pmatrix} 0.9 & 0.095 & 0.005 \\ 0.3 & 0.65 & 0.05 \\ 0.02 & 0.58 & 0.4 \end{pmatrix}$	p_{ij}
Matrice initiale de mixage	$\begin{pmatrix} 0.9 & 0.9 & 0.9 \\ 0.1 & 0.1 & 0.1 \\ 0 & 0 & 0 \end{pmatrix}$	p_0
Vecteur de probabilité initiale	$\begin{pmatrix} 0.9 \\ 0.1 \\ 0 \end{pmatrix}$	ν_0

Tab. 7.4 – Paramètres du filtre IMM

vie d'une piste mais sur un nombre limité d'itérations N^{sc} . De plus, lorsqu'une gaussienne a un poids supérieur à un seuil w_{nt} , une nouvelle piste est initialisée.

Nom	Valeur	Notation
Nombre d'itérations pour le calcul du score	3	N^{sc}
Seuil de poids pour nouvelle piste	0.8	w_{nt}

Tab. 7.5 – Paramètres de l'hybridation

7.1.5 Paramètres de détection de l'agrégat

Les paramètres de détection de l'agrégat sont décrits dans le tableau 7.6. Ils ont été déterminés en utilisant l'expertise des opérationnels.

7.1.6 Paramètres de transformation des données en probabilités

Les paramètres de transformation des données en probabilités pour les réseaux bayésiens sont décrits dans le tableau 7.7. Nous utilisons pour les déterminer certains résultats issus du pistage. Ainsi, les variations de longueur de l'agrégat ou les variations moyennes de vitesse des véhicules au cours du temps sont étudiées pour un cas simple afin d'obtenir un ordre d'idée pour les valeurs des paramètres de transformation des données en probabi-

Notation	Valeur	Nom
Distance minimale entre deux cibles pour être un agrégat	300 m	α^A
Épaisseur de la zone d'intérêt	200 m	α^C
Vitesse maximale autorisée pour un convoi	10 m.s ⁻¹	v_{max}

Tab. 7.6 – Récapitulatif des paramètres pour la mise en œuvre des réseaux bayésiens

lités. Le scénario comporte un convoi de 4 cibles distantes de 100 m entre elles (la longueur du convoi est donc de 300 m). Une cible supplémentaire double le convoi tandis qu'une autre le croise.

L'étude de la variation de la vitesse moyenne du convoi au cours du temps permet de calculer l'état de la variable S_2 . On observe sur la figure 7.1 que la variation de la vitesse sachant qu'il y a 4 cibles dans le convoi oscillent autour de 3 m.s⁻¹, mais ne dépasse jamais 5 m.s⁻¹. Par conséquent, nous choisissons les coefficients $\Delta_2 = 3$ et $\alpha_2 = 0.2$. Ainsi, si la variation est inférieure à 3 m.s⁻¹, $P\{S_2\} = 1$, si la variation est comprise entre 3 et 5 m.s⁻¹, alors $0 < P\{S_2\} < 1$ et si la variation est supérieure à 5 m.s⁻¹, alors $P\{S_2\} = 0$.

La variance de la distribution des distances séparant les cibles est également présentée en figure 7.1. Pour le convoi de 4 cibles, elle oscille autour de 1 m. Par conséquent, en utilisant la formule (4.29) avec $P\{S_6\}$ forte lorsque la variance est égale à 1 m, il vient :

$$\sigma_6 = \sqrt{\frac{V_d^2}{2 \ln(P\{S_6\})}} \quad (7.1)$$

En prenant $P\{S_6\} = 0.9$, il vient $\sigma_6 = 2$.

Concernant la longueur moyenne estimée du convoi, on observe que les fluctuations de la longueur estimée du convoi sont faibles. L'estimation de la longueur du convoi oscillent autour de 300 m. On considère donc la valeur $\Delta_7 = 20$. Ainsi, si la longueur varie de moins de 20 m, la probabilité que la variable S_7 soit dans l'état vrai est égale à 1. Si la longueur varie de plus de 20 m, alors la probabilité que la variable S_7 soit dans l'état vrai décroît. Finalement, au vu du coefficient $\alpha_7 = 0.0125$, si la longueur varie de plus de 100 m, alors la probabilité que la variable S_7 soit dans l'état vrai est égale à 0 ($P\{S_7\} = 0$).

Notation	Valeur	Nom
Paramètres du graphe flou de la variable S_2	(3, 0.2)	(Δ_2, α_2)
Paramètres du graphe flou de la variable S_7	(20, 0.0125)	(Δ_7, α_7)
Paramètre du graphe flou de la variable S_6	1	σ_6
Variance de la gaussienne pour le calcul de $P\{N_i^C \hat{N}_k^A\}$	0.5	σ_N
Paramètres du graphe flou de la variable N^A	(0.5, 0.5)	(Δ_N, α_N)

Tab. 7.7 – Récapitulatif des paramètres pour la mise en œuvre des réseaux bayésiens

Concernant les paramètres utilisés pour l'estimation du nombre de cibles ($\sigma_N, \Delta_N, \alpha_N$), ils sont choisis de la manière suivante.

Le paramètre σ_N est obtenu en considérant le cas suivant. Si la variance est forte (proche de 1), alors la probabilité est faible (on choisit 0.1). Par conséquent, $\sigma_N =$




Fig. 7.1 – Choix des paramètres des réseaux bayésiens - Longueur du convoi - Variance de la vitesse - Variance de la distance entre les cibles pour un scénario contenant un convoi de 4 cibles

$$\sqrt{\frac{1}{2} \ln(0.1)} = 0.5$$

Le paramètre Δ_N est choisit égal à 0.5. Si la différence de cardinalité entre N_i^C le nombre de cibles considéré dans le convoi et N_k^A le nombre de cibles dans l'agrégat est inférieur à 0.5, alors la probabilité $P \{N_i^C | N_k^A\}$ est égale à 1. Si cette différence est plus grande alors la probabilité diminue avec une vitesse de décroissance $\alpha_N = 0.5$, choisi telle que si la différence est supérieure à 2.5 alors, la probabilité $P \{N_i^C | N_k^A\}$ est égale à 0.

7.1.7 Paramètres de calcul des MOP

Ces paramètres concernent les mesures de performance. Ils sont semblables aux paramètres utilisés dans la littérature.

Nom	Valeur
Distance maximum pour le calcul du RMSE	150 m
(c,p) de la distance OSPA	(100, 2)

Tab. 7.8 – Paramètres de calcul des MOP

7.2 Scénario 1 : basique

7.2.1 Description du scénario 1

La durée de simulation de ce scénario est de 400 secondes. Ce scénario, bien que basique, est très complet. Il est composé de deux convois de trois cibles (cible 4 à 9) et de trois cibles indépendantes (cible 1 à 3). La cible 1 évolue complètement indépendamment des autres. Les cibles 2 et 3 se croisent entre les temps $t = 261$ s et $t = 271$ s, tandis que la cible 3 croise également le convoi 2 entre les temps $t = 221$ s et $t = 261$ s. Les cibles 2 et 3 ainsi que le convoi 2 évolue donc sur la même route qui est quasiment rectiligne. Un deuxième convoi (convoi 1) évolue sur une autre route beaucoup plus sinueuse. Les caractéristiques cinématique et de type des cibles sont décrites dans le tableau 7.9, tandis que les trajectoires sont illustrées par la figure 7.2.

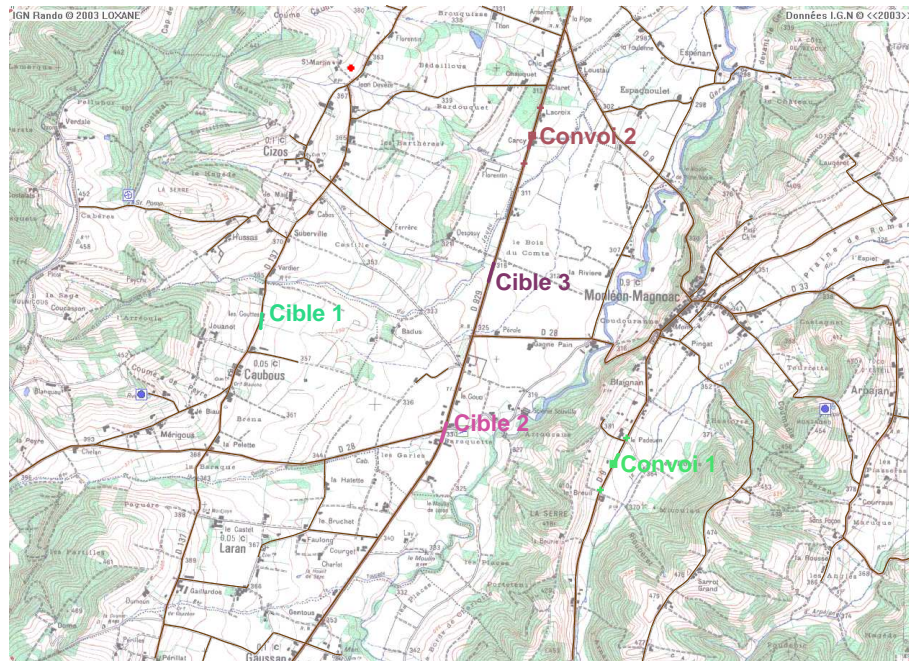


Fig. 7.2 – Trajectoire des cibles du scénario 1

	Type	t_0	t_f	v_m	Manœuvre
Cible 1	Voiture	1 s	400 s	12 m.s^{-1}	-
Cible 2	Voiture	1 s	321 s	15 m.s^{-1}	-
Cible 3	Voiture	1 s	331 s	15 m.s^{-1}	-
Convoi 1	3 jeeps $d^c = 100 \text{ m}$	1 s	400 s	8 m.s^{-1}	-
Convoi 2	3 jeeps $d^c = 200 \text{ m}$	100 s	400 s	10 m.s^{-1}	-

Tab. 7.9 – Dynamique des cibles du scénatio 1

Le cumul des plots (Figure 7.4) et la trajectoire du porteur (Figure 7.3) complète la description du scénario 1, en illustrant le problème des fausses alarmes et des bruits de

mesure.




Fig. 7.3 – Scénario 1 - ■ Plot MTI avec Doppler positif - - ■ Plot MTI avec Doppler négatif - - ○ Trajectoire du porteur - zone d'observation




Fig. 7.4 – Cumul des plots MTI du scénario 1 - ■ Plot MTI avec Doppler positif - - ■ Plot MTI avec Doppler négatif - - — Route - zone d'observation

7.2.2 Résultats du scénario 1

Nous décrivons à présent les résultats obtenus avec 500 jeux de Monte-Carlo avec les cinq algorithmes suivants :

1. l'IMM-MHT à trois modèles, désigné dans les courbes de performances par **MHT** (cf. [Kirubarajan 2000a],
2. le GM-CPHD labélisé, désigné dans les courbes de performances par **CPHD** (cf. Partie 2.4),
3. le VS-IMMC-MHT, désigné dans les courbes de performances par **VS-IMMC** [Pannetier 2006a],
4. l'algorithme qui hybride le GM-CPHD labélisé et l'IMM-MHT, désigné dans les courbes de performances par **Hybride 1** (cf. Chapitre 2),
5. l'algorithme qui hybride le GM-CPHD labélisé et le VS-IMMC-MHT, désigné dans les courbes de performances par **Hybride 2** (cf. Chapitre 3).

Ces conventions seront utilisées pour tous les résultats de simulation.

7.2.2.1 Performances globales

Les figures 7.5, 7.6, 7.7 et 7.8 comparent les performances globales des algorithmes étudiés. La figure 7.5 présente les ratios de longueur pour les différentes cibles. On observe que pour les cibles indépendantes (cibles 1-3), les cinq algorithmes produisent des performances équivalentes et satisfaisantes (ratio de longueur > 0.9). Cependant, avec les cibles appartenant à un convoi, les ratios de longueur des cibles décroissent pour les algorithmes MHT et VS-IMMC (ratio de longueur < 0.8) tandis qu'ils restent stables pour les algorithmes utilisant le filtre CPHD.




Fig. 7.5 – Ratio de longueur des pistes

La figure 7.6 présente les RMSE en position. On observe tout d’abord que les RMSE produits par le CPHD sont globalement supérieurs aux RMSE des algorithmes n’utilisant pas les coordonnées routières (supérieurs de ~ 8 m). Par ailleurs, pour toutes les cibles, on observe que les RMSE ont le même ordre de grandeur entre le MHT et la version Hybride 1, ainsi que pour le VS-IMMC et la version Hybride 2. Le filtre CPHD mis à part, on peut




Fig. 7.6 – RMSE position

faire les mêmes observations pour les RMSE en vitesse (Figure 7.7). En effet, les RMSE en vitesse sont largement supérieurs pour le CPHD par rapport aux autres (~ 8 m.s⁻¹ pour le CPHD contre < 3 m.s⁻¹ pour les autres).

Concernant, la complétude 7.8, on observe que les algorithmes utilisant le filtre CPHD ont des allures très similaires, ceci s’explique par le fait qu’avec les hybridations, c’est le filtre CPHD qui initialise les pistes. La complétude est très proche de 1 pendant toute la durée de la simulation, sauf au moment où le nombre de cibles évoluant sur la zone d’observation change (en $t = 331$ et 341 s par exemple qui correspondent à la « fin » des cibles 2 et 3). La complétude augmente alors légèrement, mais plus pour les algorithmes MHT (jusqu’à 1.3) que pour les algorithmes CPHD (≈ 1.1). Par ailleurs, les algorithmes MHT et VS-IMMC ont également des comportements très similaires sauf à la fin de la simulation où le VS-IMMC a des difficultés pour détecter les fins de pistes.

Le ratio de fausses pistes est faible (< 0.1) pour tous les algorithmes, sauf au moment de fin de pistes (en $t = 321$ et 331 s) où les algorithmes continuent à prédire des états pour les cibles qui se sont arrêtées ou sont sorties de la zone d’observation. On observe qu’à ce moment (mise en difficulté des algorithmes de pistage), le ratio de fausses pistes est plus faible pour les algorithmes utilisant le CPHD car ils mettent plus rapidement fin aux pistes.

Finalement, on observe à nouveau deux groupes dans le comportement du taux de pistes redondantes. Le groupe des algorithmes utilisant le CPHD a un taux de pistes redondantes plus faible que les algorithmes utilisant le MHT, ce qui confirme que le filtre




Fig. 7.7 – RMSE vitesse

CPHD prend mieux en charge les cibles proches.

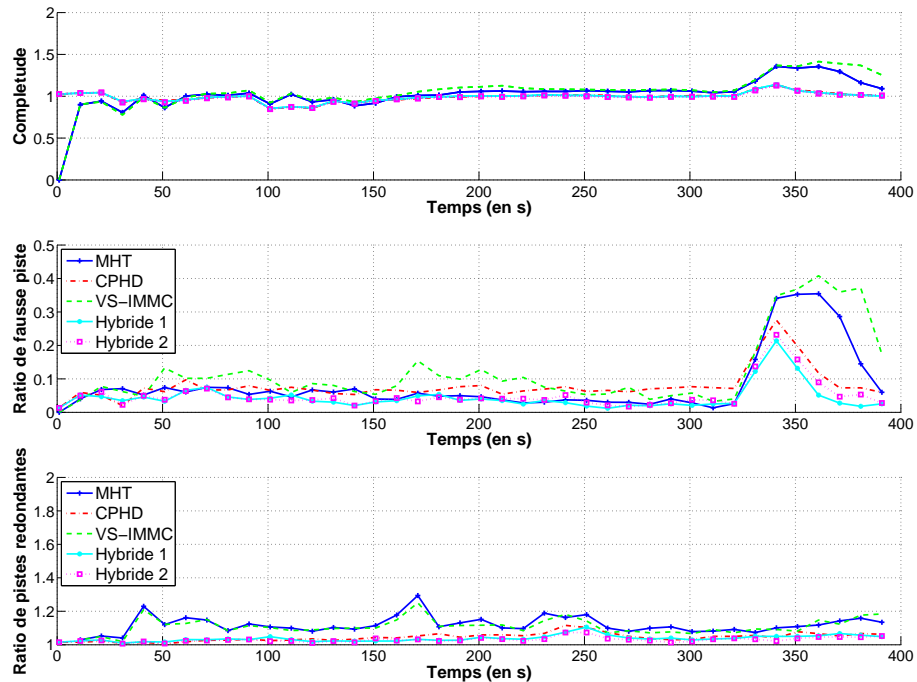


Fig. 7.8 – Complétude, ratio de fausses pistes, ratio de pistes redondantes

7.2.2.2 Performances de cibles individuelles

Nous présentons à présent les résultats observés pour quelques cibles individuelles jugées plus remarquables que les autres.

Cible 1 Nous montrons les performances liées à la cible 1 (Figure 7.9 et 7.10) car c'est la seule cible qui évolue complètement indépendamment des autres sur la zone d'observation. La continuité de pistage est bonne (≈ 1), les RMSE en position et vitesse faibles pour tous les algorithmes. Il faut juste noter la présence de pics d'erreurs pour le VS-IMMC-MHT qui correspondent probablement à des gros virages et à une sorte de décrochage de l'algorithme.




Fig. 7.9 – Continuité de pistage de la cible 1

Cible 2 La cible 2 (Figure 7.11 et 7.12) croise la cible 3 entre $t=161$ s et $t=181$ s. Par conséquent, on observe un pic important pour le taux de changement de pistes qui monte jusqu'à 0.6 pour les algorithmes MHT et VS-IMMC et 0.2 pour les autres, mais la continuité de pistage reste proche de 1 pour tous les algorithmes. On observe cependant des pics pour les RMSE vitesse en $t=171$ s (mais moins important pour les algorithmes hybrides). Globalement, le RMSE position et vitesse de Hybridation 1 tend vers le RMSE position du MHT; tandis que les RMSE de Hybridation 2 tendent vers les valeurs du VS-IMMC.

Cible 3 Les performances de la cible 3 subissent le croisement de la cible 2, mais également le croisement avec le convoi 2 qui durent entre $t=231$ s et $t=271$ s. Par conséquent, on observe les mêmes pics que pour la cible 2 pendant les instants de croisement au niveau des RMSE et du taux de changement de piste. Cependant, notons que la continuité du

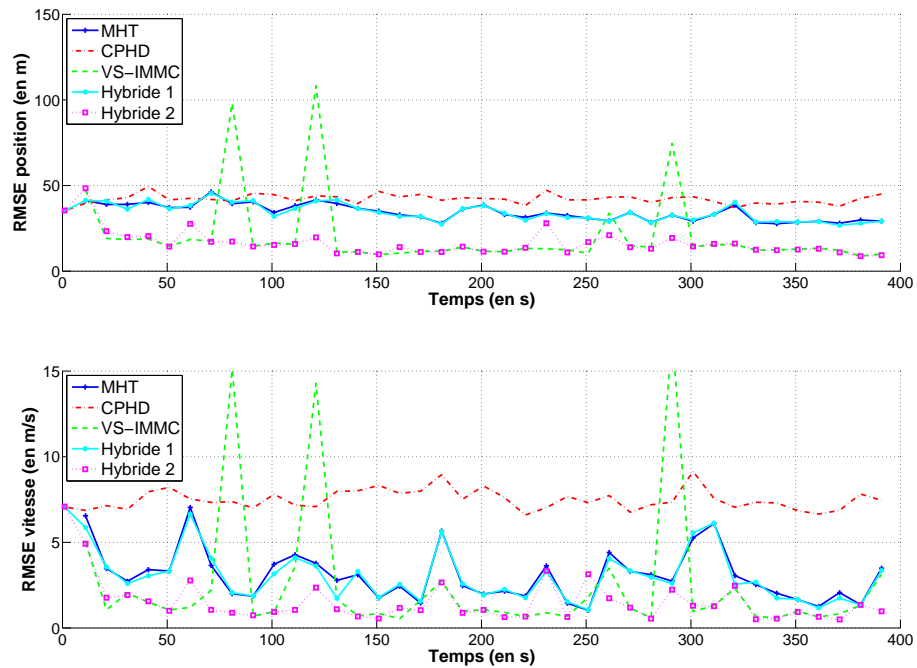


Fig. 7.10 – RMSE position et vitesse de la cible 1

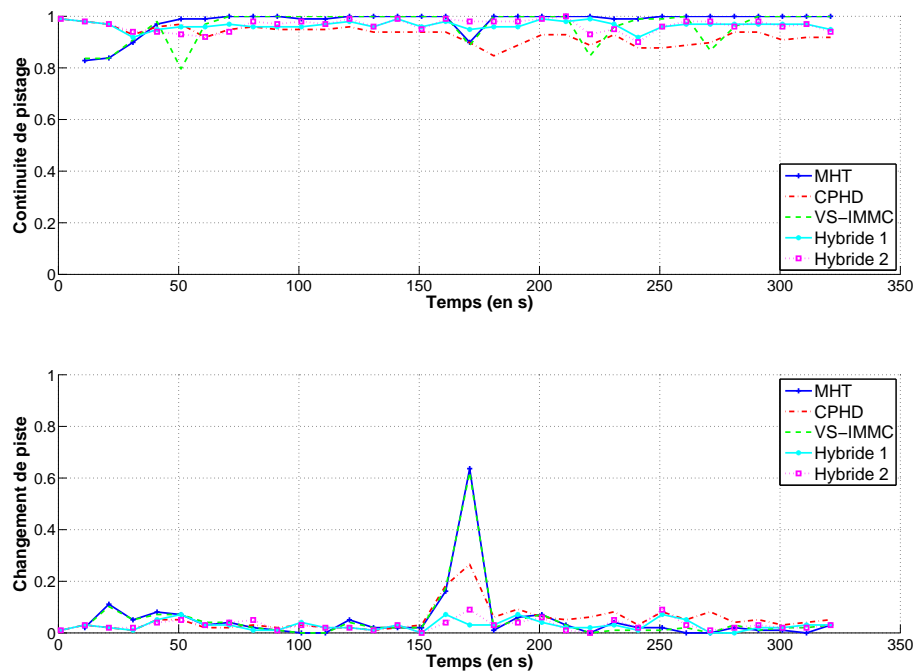


Fig. 7.11 – Continuité de pistage de la cible 2

pistage n'est pas assurée en $t = 171$ s pour les algorithmes MHT (< 0.2) tandis que les algorithmes CPHD conserve une estimation (continuité de pistage ≈ 1).

Cible 6 et 9 Les cibles 6 et 9 sont les cibles de tête de chacun des deux convois. Il apparaît que les différences de performances observées (figure 7.15, 7.16, 7.17 et 7.18), sont principalement dues au problème de l'initialisation. Les continuités de pistage sont très

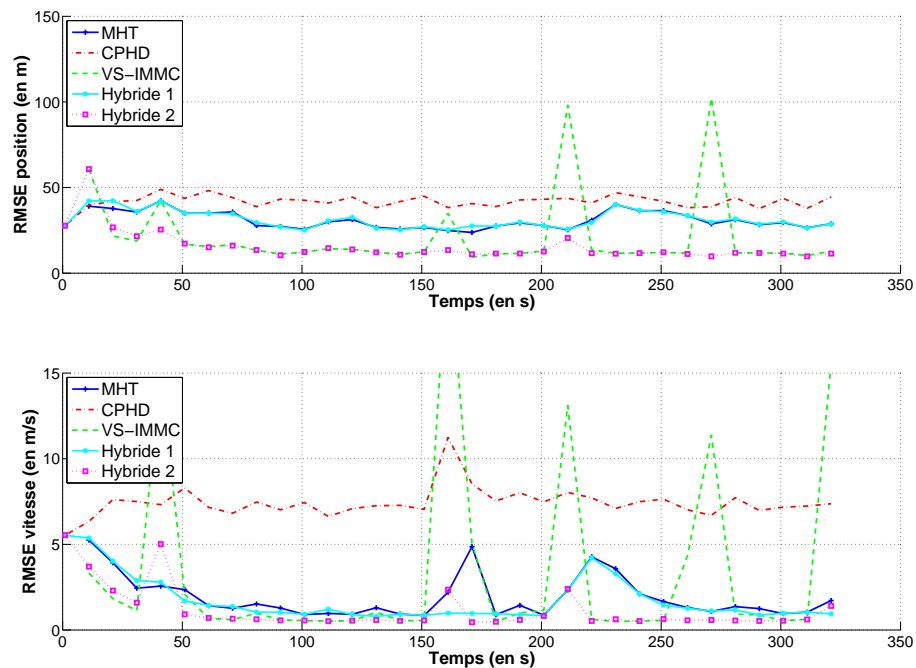


Fig. 7.12 – RMSE position et vitesse de la cible 2




Fig. 7.13 – Continuité de pistage de la cible 3

faibles pour les algorithmes MHT et croissent très lentement jusqu'aux valeurs observées pour les algorithmes utilisant le CPHD. Concernant les RMSE, on observe à nouveau que les RMSE de Hybridation 1 tendent vers les valeurs du MHT, tandis que les performances de l'algorithme Hybridation 2 tendent vers les performances du VS-IMMC.

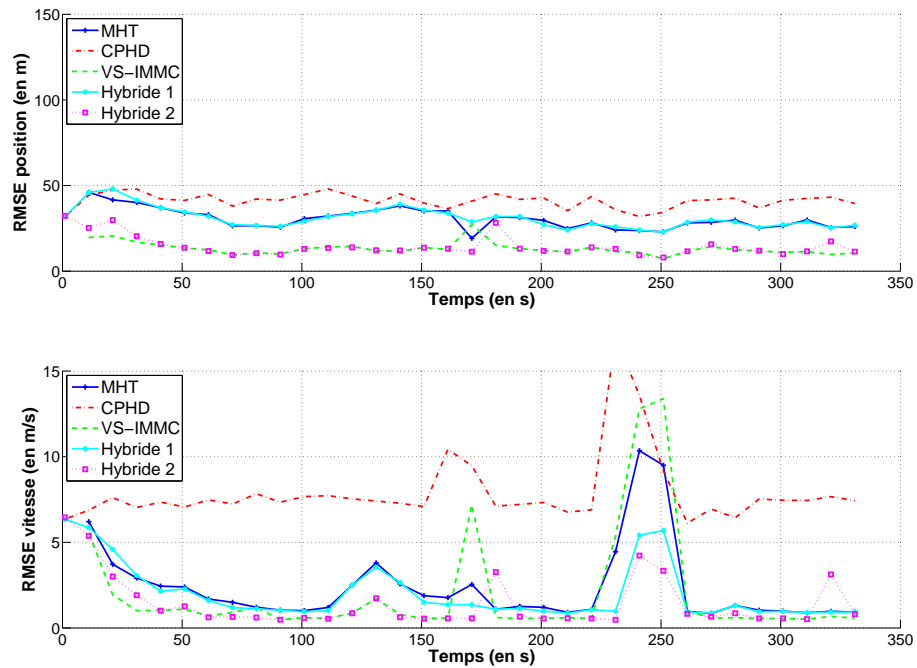


Fig. 7.14 – RMSE position et vitesse de la cible 3




Fig. 7.15 – Continuité de pistage de la cible 6

7.2.2.3 Performances avec les nouvelles métriques

La figure 7.19 résume l'ensemble des observations faites dans les parties 7.2.2.1 et 7.2.2.2. Grâce à une évaluation plus fiable du nombre de cibles dans la zone d'observation (*cf.* Cardinalité) par le filtre CPHD, les algorithmes hybrides sont capables d'initialiser et de terminer des pistes plus efficacement que les techniques du type MHT. Par conséquent,

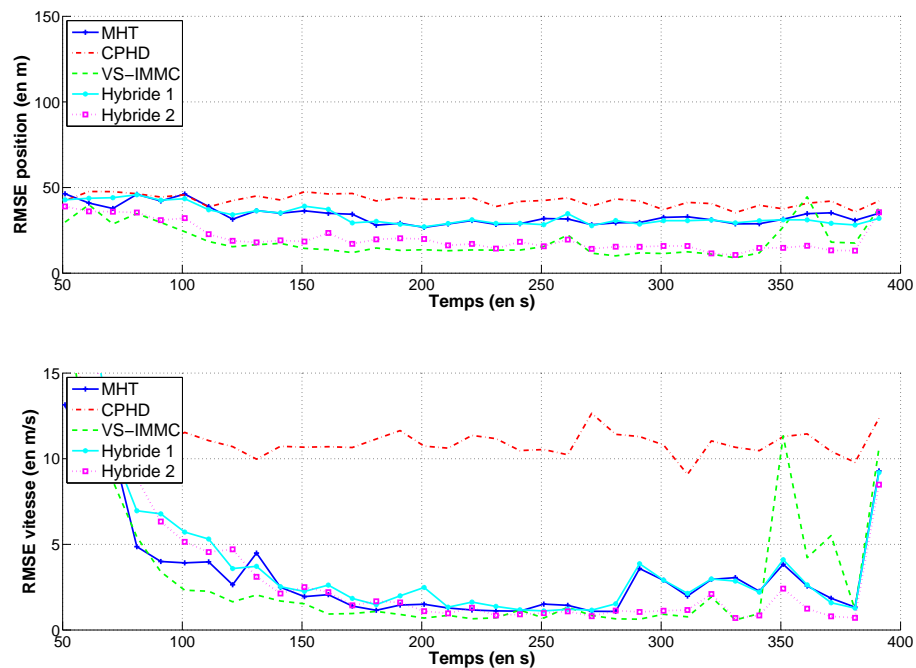


Fig. 7.16 – RMSE position et vitesse de la cible 6

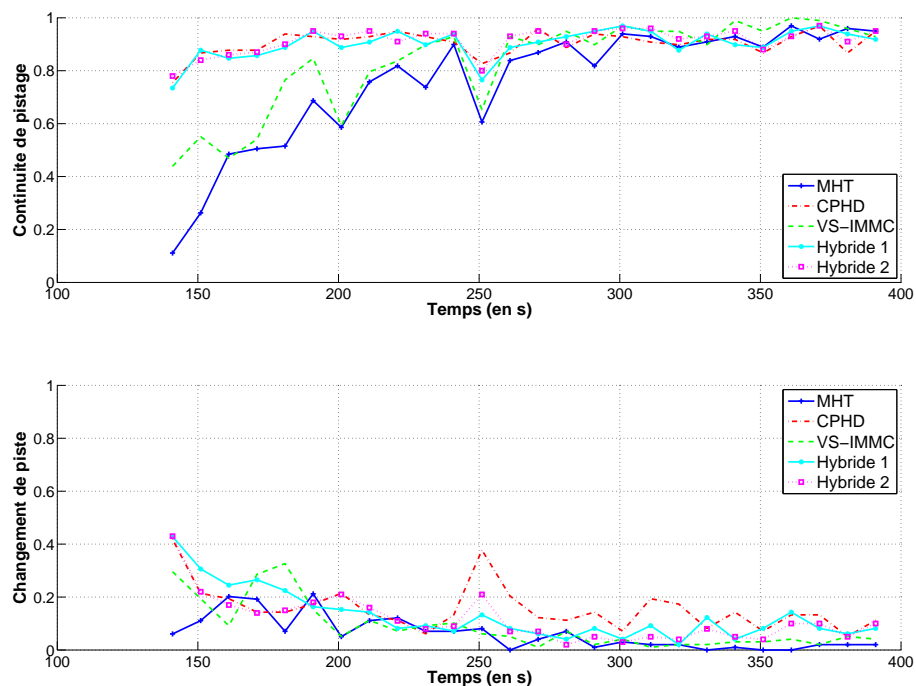


Fig. 7.17 – Continuité de pistage de la cible 9

les distances de Wasserstein et OSPA sont plus stables. Par ailleurs, si le GM-CPHD souffre tout de même d'une légère imperfection quant à l'estimation de l'état des cibles (distance OSPA plus grande que pour les autres algorithmes), les algorithmes hybrides savent tirer partie de la meilleure estimation des cibles faite par le MHT et la VS-IMMC. Par conséquent, c'est eux qui obtiennent la distance de Wasserstein et la distance OSPA

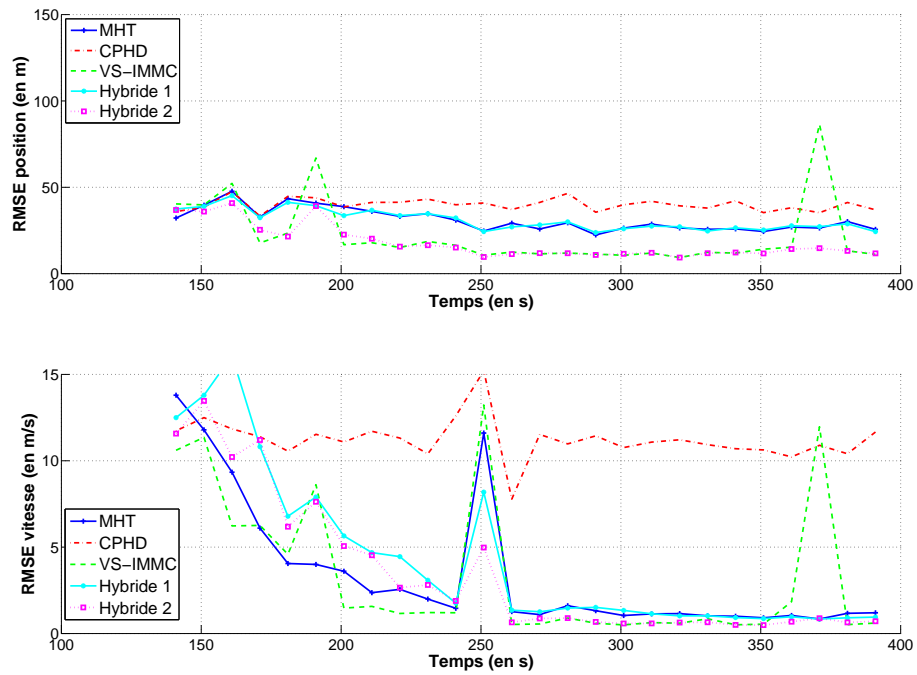


Fig. 7.18 – RMSE position et vitesse de la cible 9

la plus faible.

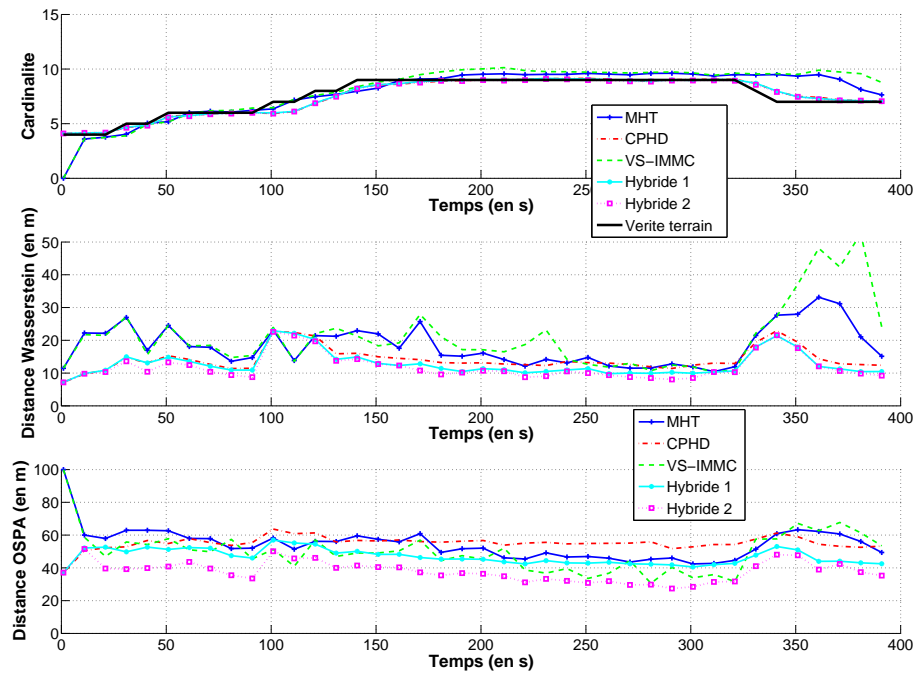


Fig. 7.19 – Cardinalité, distance de Wasserstein et OSPA

7.2.2.4 Bilan

Les objectifs décrits dans les chapitres 2 et 3 sont atteints. Grâce à ce scénario simple, nous avons mis en évidence les performances de l'algorithme hybride par rapport aux autres algorithmes MHT et CPHD pris seul. Par ailleurs, la prise en compte de l'information SIG est très importante : elle apporte une réelle plus value en terme de précision pour le pistage. Ainsi, nous avons observé que le filtre GM-CPHD souffre d'un manque de précision pour l'évaluation de l'état des cibles, particulièrement concernant la vitesse, mais qu'il les détecte par contre très rapidement. Par ailleurs, les performances des algorithmes IMM-MHT et VS-IMMC-MHT décroissent en présence de cibles proches. Finalement, les algorithmes hybrides combinent les avantages de chacune des approches sans en prendre les inconvénients. Ainsi les ratios de longueur des pistes restent très proches de 1, tandis que les valeurs des RMSE de Hybridation 1 tendent vers celles de l'IMM-MHT, et celles de Hybridation 2 vers celle du VS-IMMC-MHT.

7.3 Scénario 2 : dépassement d'un convoi

Ce second scénario illustre le problème des manœuvres entourant un convoi et le problème des interactions entre un convoi et son environnement. Il contient un convoi de taille relativement longue (6 cibles) évoluant sur la route principale du sud vers le nord et une cible individuelle vient le doubler entre les temps $t = 191$ s et $t = 351$ s. Les caractéristique cinématique et de type des cibles sont décrites dans le tableau 7.10, tandis que les trajectoires sont illustrées par la figure 7.20. La durée de simulation de ce scénario est de 400 secondes.

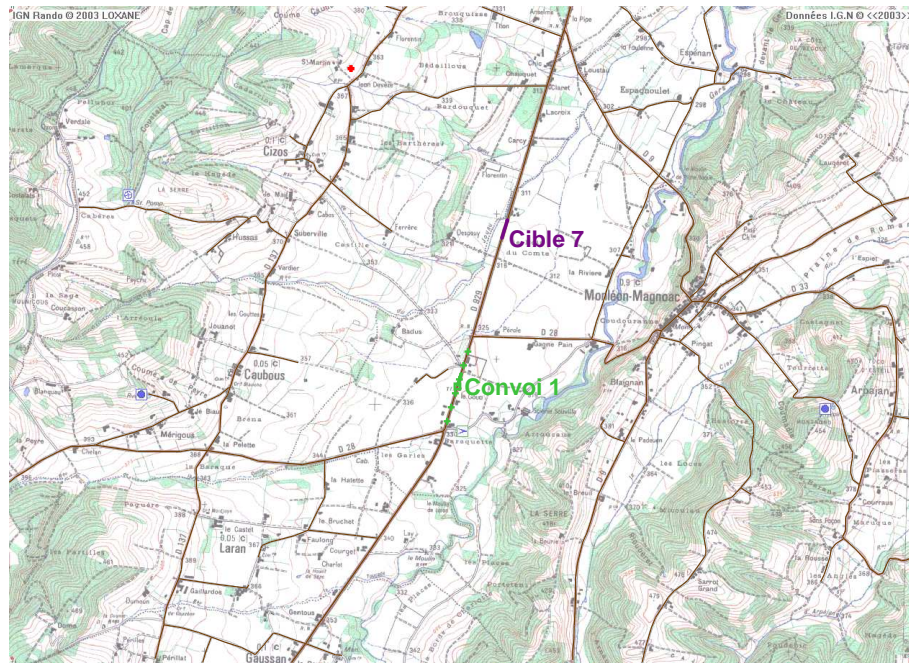


Fig. 7.20 – Trajectoire des cibles du scénario 2

	Type	t_0	t_f	v_m	Manœuvre
Convoi 1	6 vabs $d^c = 100$ m	1 s	500 s	10 m.s^{-1}	-
Cible 7	Voiture	1 s	431 s	15 m.s^{-1}	-

Tab. 7.10 – Dynamique des cibles du scénario 2

Le cumul des plots (Figure 7.22) et la trajectoire du porteur (Figure 7.21) complètent la description du scénario 2.

7.3.1 Résultats du pistage pour le scénario 2

Nous décrivons à présent les résultats obtenus avec 100 jeux de Monte-Carlo avec les cinq algorithmes énumérés précédemment.




Fig. 7.21 – Scénario 2 - \square Plot MTI avec Doppler positif - \square Plot MTI avec Doppler négatif - \circ Trajectoire du porteur - \blacksquare zone d'observation




Fig. 7.22 – Cumul des plots MTI du scénario 2 - \square Plot MTI avec Doppler positif - \square Plot MTI avec Doppler négatif - --- Route - \blacksquare zone d'observation

7.3.1.1 Performances globales

Le scénario 2 contient donc 6 cibles qui évoluent dans un convoi et une cible qui interagit avec le convoi. Toutes les cibles sont donc proches et ce scénario risque de mettre en difficulté les approches de type MHT, puisque même la cible indépendante interagit avec le convoi.

En regardant le ratio de longueur des pistes (Figure 7.23), on observe que les ratios sont bien inférieurs à ceux observés pour le scénario 1 avec les approches de type MHT (inférieurs à 0.7) ; tandis qu'ils sont du même ordre de grandeur pour les approches CPHD et hybrides (~ 0.9).




Fig. 7.23 – Ratio de longueur des pistes

Par conséquent, il apparaît de façon encore plus flagrante que l'estimation de l'état des cibles sera meilleure avec les approches hybrides qu'avec les approches MHT (Figure 7.24 et 7.25). Si le CPHD affiche toujours une erreur d'estimation légèrement supérieure en position et très supérieure en vitesse, l'approche Hybridation 1 affiche cette fois des erreurs globalement inférieures en position (31 *vs.* 35) par rapport au MHT et à peu près égale en vitesse, tandis que l'approche Hybridation 2 affiche également des erreurs globalement inférieures en position (14 *vs.* 22) par rapport au VS-IMMC et à peu près égale en vitesse. En ce qui concerne la complétude (figure 7.26), elle est toujours très proche de 1 avec les approches utilisant le CPHD, tandis que les approches de type MHT montrent encore des difficultés à l'initialisation et à la fin des pistes. Le ratio de fausses pistes fournit une même allure pour les cinq approches, même si les pics observés lors des changements de cardinalité pour le nombre de cibles sur la zone d'observation sont moins importants pour les approches utilisant le CPHD.

Finalement, avec le ratio de pistes redondantes, les approches de type MHT montrent clairement l'origine du problème : la complétude est proche de 1, le taux de fausses pistes est proche de 0, mais les ratios de fausses pistes sont faibles. Par conséquent, le ratio de pistes redondantes est très haut avec les approches de type MHT (~ 1.5) par rapport aux approches utilisant le CPHD (< 1.2).




Fig. 7.24 – RMSE position




Fig. 7.25 – RMSE vitesse

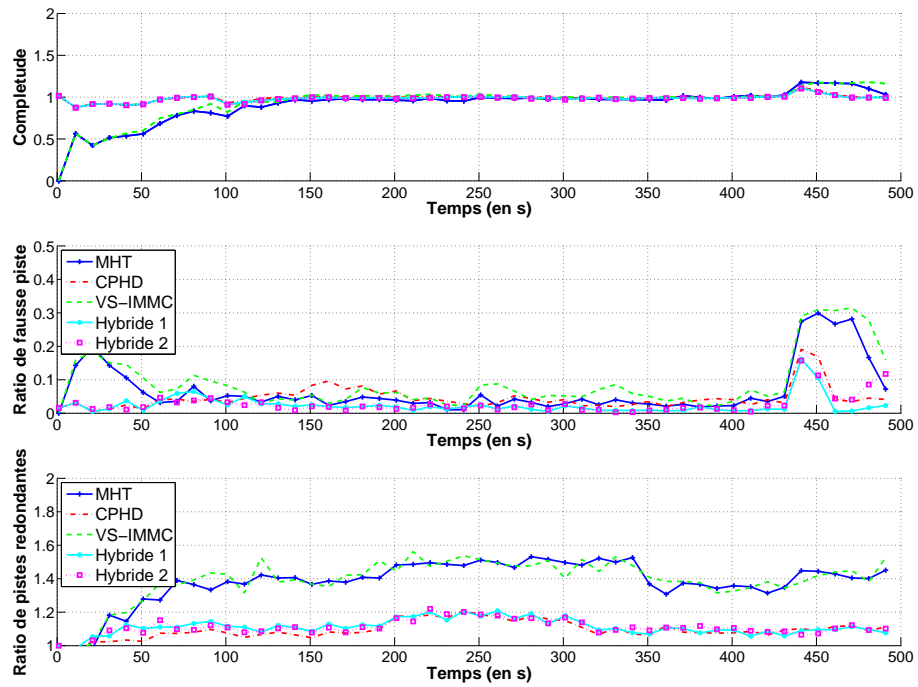


Fig. 7.26 – Complétude, ratio de fausses pistes, ratio de pistes redondantes

7.3.1.2 Performances de cibles individuelles

Nous montrons à présent les résultats pour une partie des cibles :

- la cible 1 individuelle,
- la cible 3 : véhicule de tête du convoi,
- la cible 4-5 : deux véhicules au milieu du convoi.

Cible 1 Pour la cible 1, il apparaît que deux pics apparaissent entre les temps $t = 191$ s et $t = 351$ s pour les l'erreur en vitesse qui correspondent aux instants où la cible 1 commence et termine de dépasser le convoi. Les cinq algorithmes fournissent des performances équivalentes. Le pic du changement de pistes en $t = 301$ s correspond au moment où la cible fait un virage.




Fig. 7.27 – Continuité de pistage de la cible 1

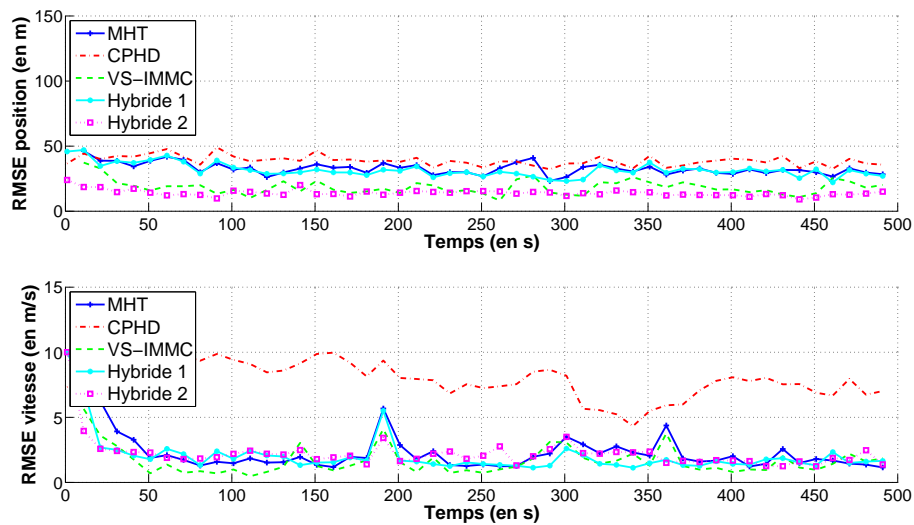


Fig. 7.28 – RMSE position et vitesse de la cible 1

Cible 2, 3 et 4 Sinon, pour les cibles du convoi on observe également un pic pour le RMSE vitesse qui correspond au moment où la cible 1 les dépasse. Par conséquent, le pic apparaît d'abord sur la cible 6 (véhicule de queue) et se décale dans le temps pour les cibles qui la précèdent comme on peut l'observer sur les figures 7.29 à 7.34 (cible 4 : pic en $t = 201$ s, Cible 3 : pic en $t = 211$ s, Cible 2 : pic en $t = 221$).

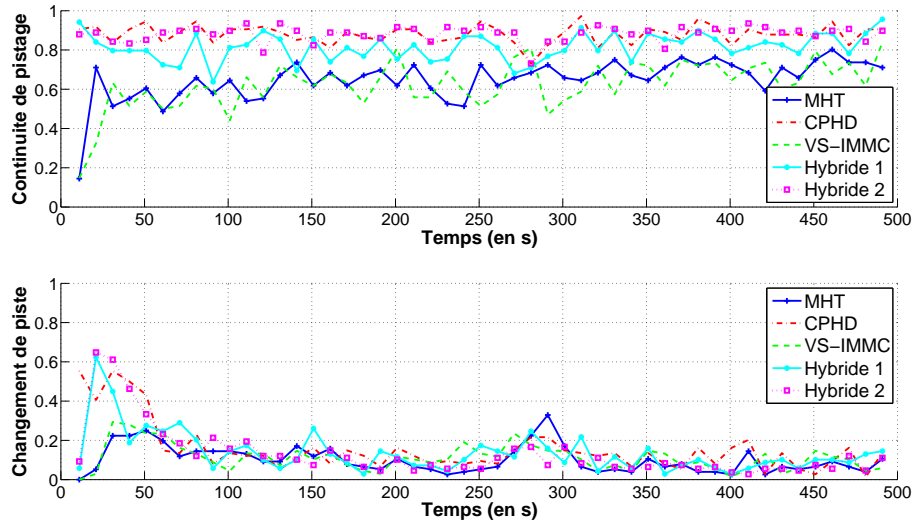


Fig. 7.29 – Continuité de pistage de la cible 2




Fig. 7.30 – RMSE position et vitesse de la cible 2




Fig. 7.31 – Continuité de pistage de la cible 3

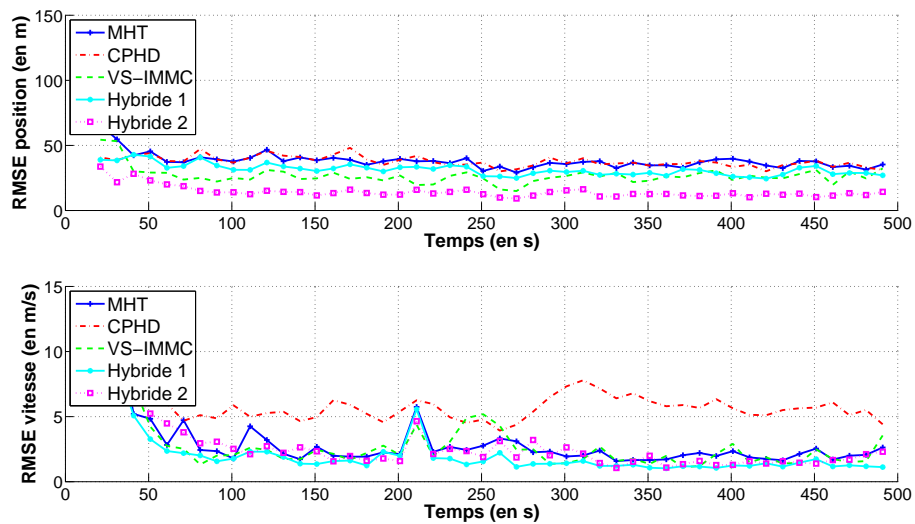


Fig. 7.32 – RMSE position et vitesse de la cible 3




Fig. 7.33 – Continuité de pistage de la cible 4

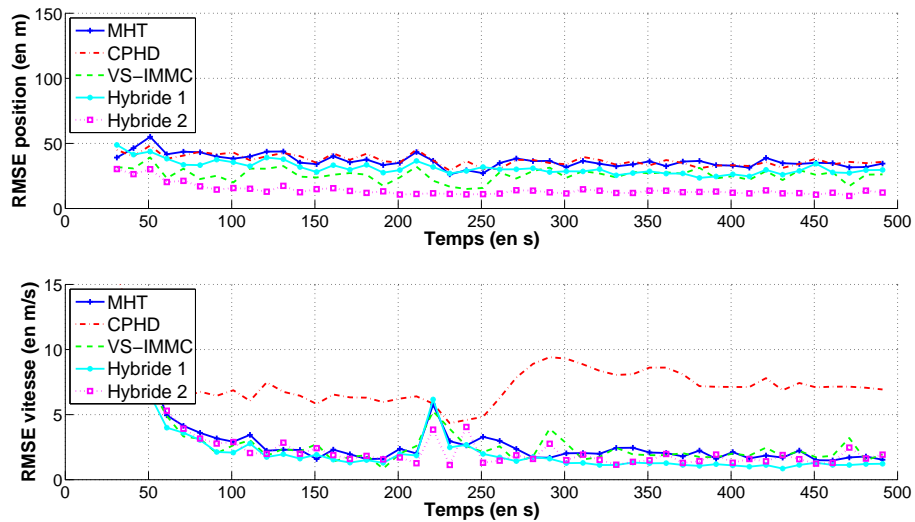


Fig. 7.34 – RMSE position et vitesse de la cible 4

7.3.1.3 Performances avec les nouvelles métriques

Les distances OSPA et de Wasserstein présentées en figure 7.35 résument les performances que nous avons observées précédemment. En effet, cette fois, les cibles interagissent toutes entre elles et sont donc difficiles à pister pour les algorithmes utilisant le MHT. Par conséquent, la distance OSPA est deux fois supérieure pour l'algorithme VS-IMMC par rapport à l'algorithme Hybridation 2, car elle est fortement pénalisée par un taux très haut de pistes redondantes.




Fig. 7.35 – Distances de Wasserstein et OSPA pour le scénario 2

7.3.2 Résultats pour la détection de convois pour le scénario 2

7.3.2.1 Résultat avec la vérité terrain

Afin de vérifier la validité du modèle de comportement du convoi, nous le testons sur la vérité terrain simulée. Ainsi, les entrées ne sont pas bruitées et elles suivent exactement le comportement du convoi modélisé. Nous obtenons alors les probabilités présentées en figure 7.36. Les courbes bleues représentent les probabilités S_9 d'être un convoi. Les types de pointillés représentent le nombre de cibles considérés dans le convoi. On suppose qu'à l'instant initial, on a reçu l'information qu'il y avait un véhicule militaire donc $P\{S_5\} = 1$. Tout d'abord, nous remarquons que la probabilité d'avoir un convoi de 6 cibles (courbe bleue pointillée) convergent très rapidement vers une probabilité très forte (0.85), ce qui est normal puisque tous les critères de convoi sont remplis et donc toutes les probabilités de S_2 , S_3 , S_4 , S_6 et S_7 sont égales à 1.

Le calcul de la probabilité d'avoir un convoi de 7 cibles (courbe bleue continue) commence lorsque la cible qui va doubler le convoi devient proche de celui-ci à $t = 120$ s. Cependant, au début, elle n'est pas très forte puisque deux des critères, celui de constance de la distance entre les véhicules (S_6) et celui de constance de la longueur du convoi (S_7), ne sont pas vérifiés. Puis, la probabilité d'être un convoi converge pendant la durée du dépassement (jusqu'à $t = 340$ s) vers une valeur plus faible que celle d'avoir un convoi de 6 cibles (0.75), puisque les autres critères ne sont pas aussi bien vérifiés : la cible supplémentaire a une vitesse supérieure à la vitesse limite (S_1), la vitesse n'est pas constante (S_2) et la distance entre les véhicules est variable. Puis à partir de $t = 340$ s, la probabilité




Fig. 7.36 – Probabilité de détection de convoi avec la vérité terrain

chute. En effet, la cible supplémentaire a fini de doubler le convoi et s'éloigne du convoi, faisant tendre $P\{S_6\}$ vers 0. Une fois que la cible supplémentaire n'est plus détectée dans l'agrégat, la probabilité d'avoir un convoi de 7 cibles continue cependant à être calculée et elle converge vers la valeur de la probabilité d'avoir un convoi de 6 cibles, ce qui est normal puisque on utilise les mêmes valeurs en entrée.

Cependant, il faut tout de même noter que nous utilisons la vérité terrain non bruitée. Or, pendant la période de dépassement, la différence entre la probabilité d'avoir un convoi de 6 cibles et un convoi de 7 cibles n'est que de 0.1. On peut s'attendre avec des mesures bruitées à ce qu'il devienne difficile de distinguer les deux cas.

7.3.2.2 Résultat avec les pistes GMTI

La figure 7.37 présente le calcul de la probabilité que le convoi 1 soit détecté. Cette probabilité a l'allure d'une courbe de croissance exponentielle qui tend vers la valeur 0.6. En $t = 150$ s et $t = 350$ s, on observe deux chutes dans la croissance de la courbe, qui correspondent au moment où la cible individuelle « entre » et « sort » du convoi.

Afin d'évaluer le nombre de cibles du convoi, on calcule les probabilités d'avoir N_k^{A1} cibles où N_k^{A1} est l'ensemble des valeurs différentes prises par la séquence $N_{1:k}^A$ des nombres de cibles dans l'agrégat (cf. Figure 7.38).

Dans notre scénario, le convoi est formé de 6 cibles. De plus, pendant la phase de doublement, le nombre de cibles dans l'agrégat est de 7 cibles. Cependant, comme ce nombre de cibles dans l'agrégat vient d'une estimation \hat{N}_k^A et que N_k^A est pris comme le nombre entier correspondant, il y a des erreurs dans l'estimation du nombre de cibles dans l'agrégat. Ainsi, bien qu'il y ait 6 cibles dans le convoi, il arrive que nous n'ayons que 5

états estimés pour mettre à jour la probabilité d’avoir un convoi. Ainsi, nous calculons les probabilités d’avoir 5, 6 et 7 cibles dans le convoi. Les probabilités d’avoir un convoi de 5 et 6 cibles ont des allures similaires. En effet, lorsque le nombre de cibles estimés dans l’agrégat est de 6 cibles et que l’on continue à calculer la probabilité d’avoir un convoi de 5 cibles, on prend, pour l’estimation, les 5 cibles, parmi les 6, qui sont le mieux disposées spatialement pour former un convoi (la combinaison de cibles qui réduit la variance dans l’ensemble des distances successives entre deux cibles). Finalement, les probabilités d’avoir un convoi de 5 et 6 cibles ont l’allure de courbes de croissance exponentielle qui tendent vers 0.6, mais sans les chutes de probabilités qui apparaissaient sur la figure 7.37. En effet, on parvient bien à sélectionner les 6 (ou 5) cibles parmi les 7 lors de la phase de doublement, qui appartiennent bien au convoi.

Finalement, afin de discriminer les cas 5 et 6 cibles, on calcule la probabilité d’avoir un convoi de N^A cibles connaissant la séquence des nombres estimés de cibles dans l’agrégat. En effet, si on calcule la probabilité d’avoir un convoi de 5 cibles alors qu’on détecte 6 cibles depuis plusieurs itérations, on peut pénaliser la probabilité d’avoir un convoi de 5 cibles. Dans la figure 7.39, on observe effectivement que la probabilité d’avoir un convoi de 6 cibles est plus forte que la probabilité d’avoir un convoi de 5 cibles. La différence entre les deux probabilités est particulièrement forte pendant la phase de croisement où le nombre estimé de cibles dans le convoi est proche de 7.




Fig. 7.37 – Probabilité de détection du convoi 1

7.3.3 Bilan

Dans ce scénario, composé uniquement de cibles proches les unes des autres, nous avons confirmé les performances des algorithmes hybrides en terme de pistage. Nous combinons ainsi les capacités de détection des cibles du filtre CPHD avec la précision de l’estimation de l’état des cibles de l’IMM-MHT, avec ou sans contrainte.




Fig. 7.38 – Probabilité de détection du convoi 1 de taille N^C




Fig. 7.39 – Probabilité de détection du convoi 1 de taille N^C connaissant $N_{k_0|k}^A$

Nous avons également prouvé la justesse du modèle de convoi proposé, puisque la probabilité d'être un convoi croît au cours du temps. Par ailleurs, l'introduction du nombre de cibles dans le calcul permet de détecter des manœuvres simples comme un dépassement.

7.4 Scénario 3 : complexe

7.4.1 Description du scénario 3

La durée de simulation de ce scénario est de 600 secondes. Ce scénario est un des scénarios les plus complexes que nous ayons imaginé dans le cadre de la détection de convoi. Non seulement la quantité de cibles est importante (14), mais en plus, les manœuvres qui y ont lieu sont élaborées et la nature des agrégats est difficile à évaluer (on a un véritable convoi et un agrégat créé à cause d'un véhicule lent qui engendre un ralentissement). Globalement, il contient :

- un convoi (cibles 3 à 6) de quatre cibles évoluant sur la route principale du nord vers le sud,
- un tracteur (cible 1) qui évolue très lentement sur la même route mais du sud vers le nord. Il est doublé par deux cibles (cibles 2 et 10), puis crée un ralentissement ; les cibles 7, 8 et 9 sont bloquées derrière lui et ne peuvent pas le doubler à cause de la présence du convoi sur la voie en face,
- trois cibles (cibles 11-13) indépendantes qui apparaissent à différents instants sur la zone d'observation,
- une cible (cible 14) qui s'arrête à un carrefour pour laisser passer le convoi. Cela signifie qu'elle ne fournit plus aucune mesure entre les temps $t = 361$ s et $t = 481$ s.

Les caractéristiques cinématique et de type des cibles sont décrites dans le tableau 7.11, tandis que les trajectoires sont illustrées par la figure 7.40.

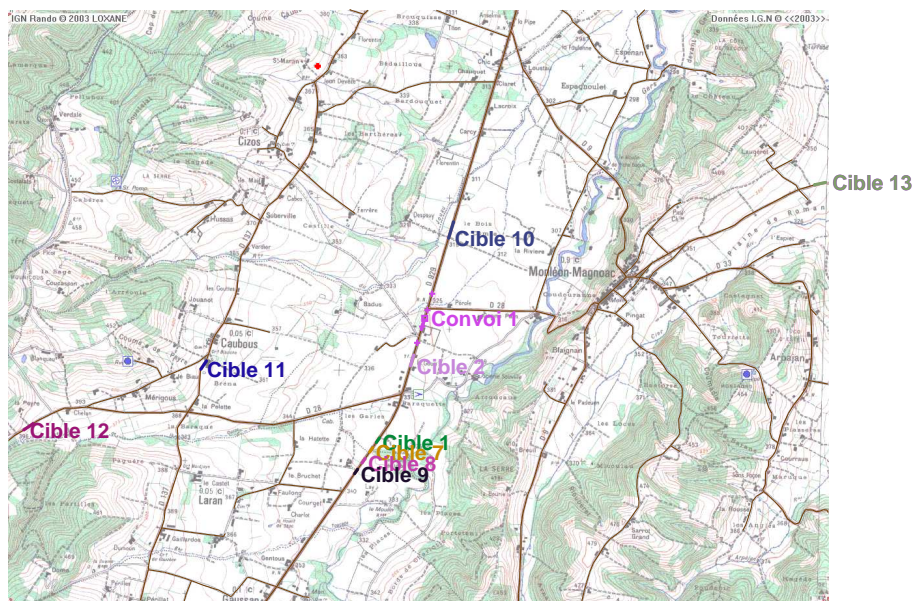


Fig. 7.40 – Trajectoire des cibles du scénario 3

Le cumul des plots (Figure 7.42) et la trajectoire du porteur (Figure 7.41) complète la description du scénario 3.

	Type	t_0	t_f	v_m	Manœuvre
Cible 1	Tracteur	1 s	600 s	5 m.s ⁻¹	-
Cible 2	Voiture	51 s	581 s	15 m.s ⁻¹	-
Convoi 1	3 jeeps $d^c = 100$ m	1 s	600 s	8 m.s ⁻¹	$\ddot{x}_2 = -1$ m.s ⁻² ; $t = 241$ s; 2 s
Cible 7	Voiture	121 s	600 s	10 m.s ⁻¹	$\ddot{x}_2 = -1$ m.s ⁻² ; à $t = 231$ s; 5 s $\ddot{x}_2 = +1$ m.s ⁻² ; $t = 431$ s; 7 s
Cible 8	Voiture	141 s	600 s	10 m.s ⁻¹	$\ddot{x}_2 = -1$ m.s ⁻² ; à $t = 241$ s; 5 s $\ddot{x}_2 = +1$ m.s ⁻² ; $t = 441$ s; 5 s
Cible 9	Voiture	161 s	600 s	10 m.s ⁻¹	$\ddot{x}_2 = -1$ m.s ⁻² ; à $t = 261$ s; 5 s $\ddot{x}_2 = +1$ m.s ⁻² ; $t = 461$ s; 5 s
Cible 10	Voiture	101 s	600 s	15 m.s ⁻¹	-
Cible 11	Voiture	101 s	600 s	9 m.s ⁻¹	-
Cible 12	Voiture	321 s	600 s	10 m.s ⁻¹	-
Cible 13	Voiture	421 s	600 s	10 m.s ⁻¹	$\ddot{x}_2 = -2$ m.s ⁻² ; $t = 521$ s; 5 s $\ddot{x}_2 = +2$ m.s ⁻² ; $t = 571$ s; 5 s
Cible 14	Voiture	271 s	600 s	10 m.s ⁻¹	$\ddot{x}_2 = -2$ m.s ⁻² ; à $t = 357$ s; 5 s $\ddot{x}_2 = +2$ m.s ⁻² ; $t = 476$ s; 5 s

Tab. 7.11 – Dynamique des cibles du scénario 3 - Chaque ligne d'une case manœuvre contient trois éléments qui sont les valeurs, le début et la durée de l'accélération.




Fig. 7.41 – Scénario 3 - ■ Plot MTI avec Doppler positif - ■ Plot MTI avec Doppler négatif - ○ Trajectoire du porteur - ■ zone d'observation




Fig. 7.42 – Cumul des plots MTI du scénario 3 - \square Plot MTI avec Doppler positif - \square Plot MTI avec Doppler négatif - — Route - \blacksquare zone d'observation

7.4.2 Résultats du scénario 3 pour la détection de convois

Nous décrivons à présent les résultats obtenus avec 100 jeux de Monte-Carlo avec les cinq algorithmes.

7.4.2.1 Performances globales

Les performances globales obtenues avec le scénario 3 sont conformes aux performances obtenues avec les scénarios 1 et 2. Les ratios de longueur des pistes (Figure 7.45) montrent que les algorithmes utilisant le MHT ont des difficultés à pister les cibles proches : les ratios de longueur sont inférieurs à 0.7, tandis que pour les algorithmes utilisant le CPHD, les ratios de longueur restent constants (entre 0.8 et 0.9). Dans les scénarios précédents, les ratios de longueur étaient toujours supérieurs à 0.9, mais avec le scénario 3, les manœuvres et les trajectoires sont plus complexes donc le ratio de longueur est légèrement inférieur à 0.9, mais reste quand même bon au vu de la complexité du scénario. Avec les cibles indépendantes 13 et 14, cependant, les ratios de longueur sont supérieurs pour les algorithmes utilisant le MHT. Cela est sûrement dû aux accélérations, décélérations et arrêts de ces cibles qui sont mieux pris en charge par les IMM.

Concernant les RMSE (figure 7.43 et 7.44), ils sont supérieurs pour le filtre CPHD aussi bien en position qu'en vitesse (en moyenne 38 m et 8 m.s^{-1}). Pour les autres algorithmes, on observe que les RMSE en position et en vitesse de Hybridation 1 tendent vers les valeurs de l'IMM-MHT, tandis que pour Hybridation 2, elles tendent vers les valeurs du




Fig. 7.43 – RMSE position

VS-IMMC-MHT. Il est tout de même bon de noter, que pour les cibles appartenant à des agrégats, les RMSE position sont globalement plus faibles pour les algorithmes hybrides.

Concernant la complétude (*cf.* Figure 7.46), comme pour le scénario 2, la complétude est plus proche de 1 avec les algorithmes utilisant le CPHD qu'avec les algorithmes utilisant le MHT. Le taux de fausse piste est bas (il apparaît plus bas que pour les scénarios précédents car il y a plus de cibles en mouvement), tandis que le taux de pistes redondantes est très haut pour les algorithmes utilisant le MHT (1.3 contre 1.1 pour les autres).




Fig. 7.44 – RMSE vitesse




Fig. 7.45 – Ratio de longueur des pistes

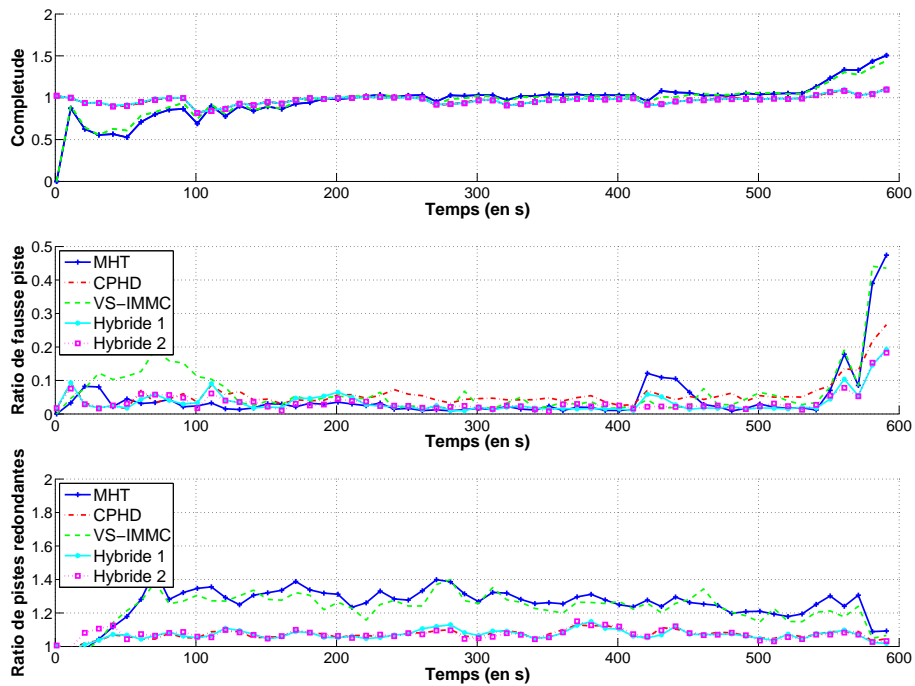


Fig. 7.46 – Complétude, ratio de fausses pistes, ratio de pistes redondantes

7.4.2.2 Performances de cibles individuelles

Cible 1 Il s'agit du tracteur. Les 5 algorithmes de pistage ont des allures proches pour la continuité de pistage et le taux de changement de piste. Par conséquent, les RMSE de Hybridation 1 et Hybridation 2 tendent vers les mêmes valeurs que pour l'IMM-MHT et la VS-IMMC-MHT.




Fig. 7.47 – Continuité de pistage de la cible 1

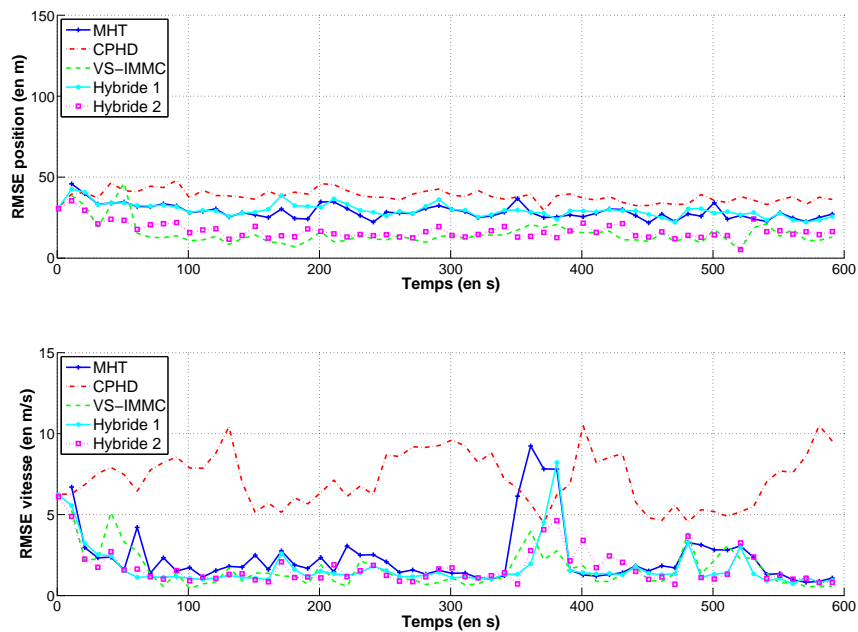


Fig. 7.48 – RMSE position et vitesse de la cible 1

Cible 2 C'est la cible qui reste quelques instants derrière le tracteur puis le double en $t = 110$ et croise également le convoi 1 entre $t = 300$ s et $t = 350$ s. Lorsque la cible 2 entre en interaction avec d'autres cibles, les performances des algorithmes utilisant le MHT décroissent.




Fig. 7.49 – Continuité de pistage de la cible 2

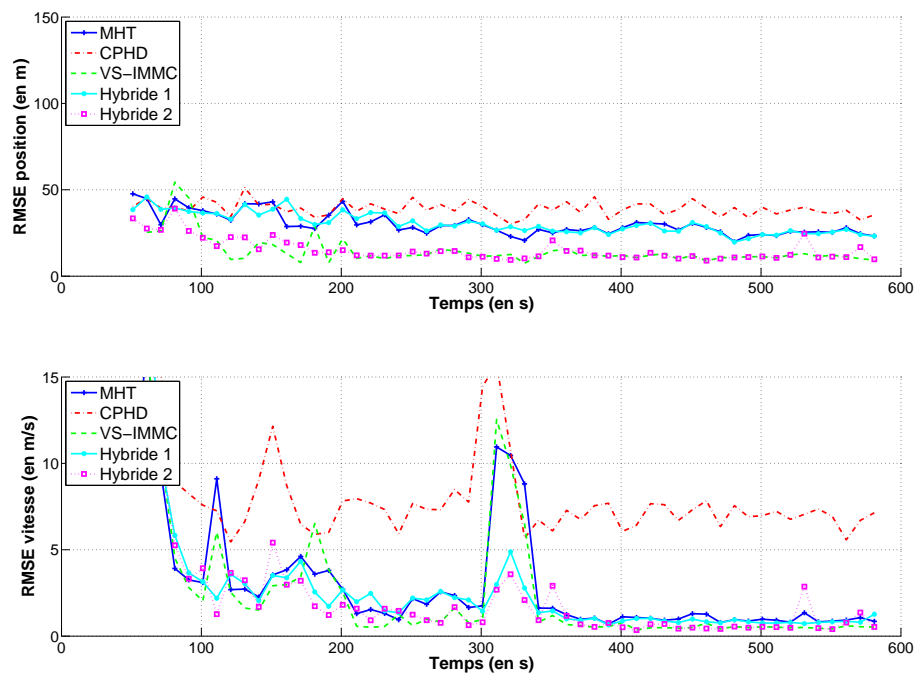


Fig. 7.50 – RMSE position et vitesse de la cible 2

Cible 3 Il s'agit d'une des cibles qui reste derrière le tracteur en attendant de pouvoir le doubler après le croisement avec le convoi. Elle est donc très proche du convoi pendant plusieurs itérations. Par conséquent, les algorithmes utilisant le MHT montrent de réelles difficultés à la détecter (la continuité de pistage est faible : 0.6).

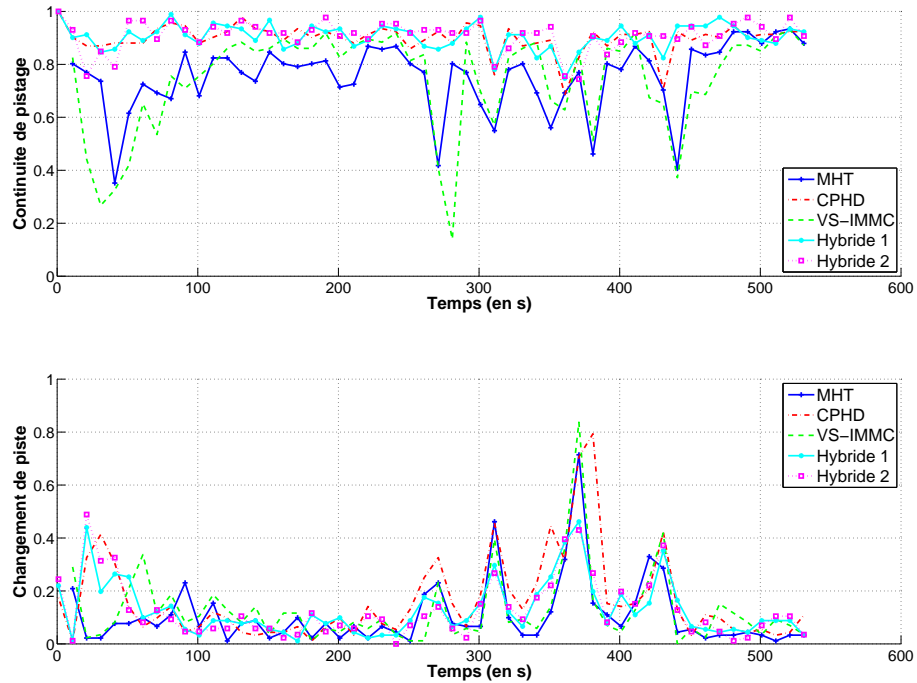


Fig. 7.51 – Continuité de pistage de la cible 3

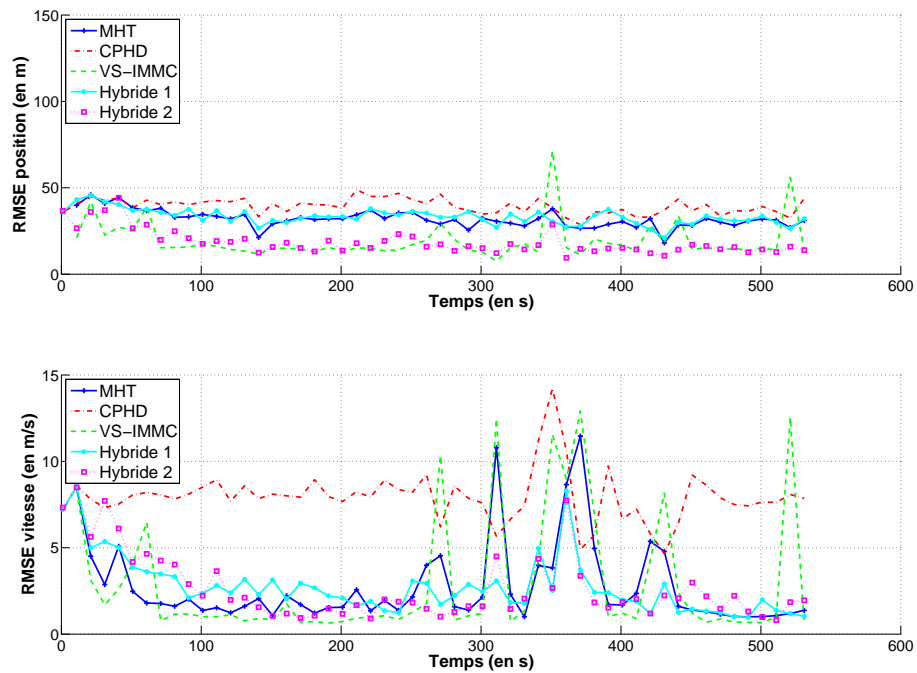


Fig. 7.52 – RMSE position et vitesse de la cible 3

Cible 9 Il s'agit d'une autre des cibles qui reste coincée derrière le tracteur en attendant de pouvoir le doubler. Les observations sur ses performances sont les mêmes que pour la cible 3, mais en pire au niveau de la continuité du pistage (< 0.5). La hausse du taux de changement de piste entre $t = 371$ s et $t = 421$ s correspond au moment où la cible 9 croise le convoi.




Fig. 7.53 – Continuité de pistage de la cible 9




Fig. 7.54 – RMSE position et vitesse de la cible 9

Cible 13 C'est une cibles individuelle qui n'a aucune interaction avec les autres. Les performances sont globalement les mêmes pour les 5 algorithmes. On peut juste observer que les algorithmes utilisant le CPHD montrent des difficultés à initialiser la piste.




Fig. 7.55 – Continuité de pistage de la cible 13

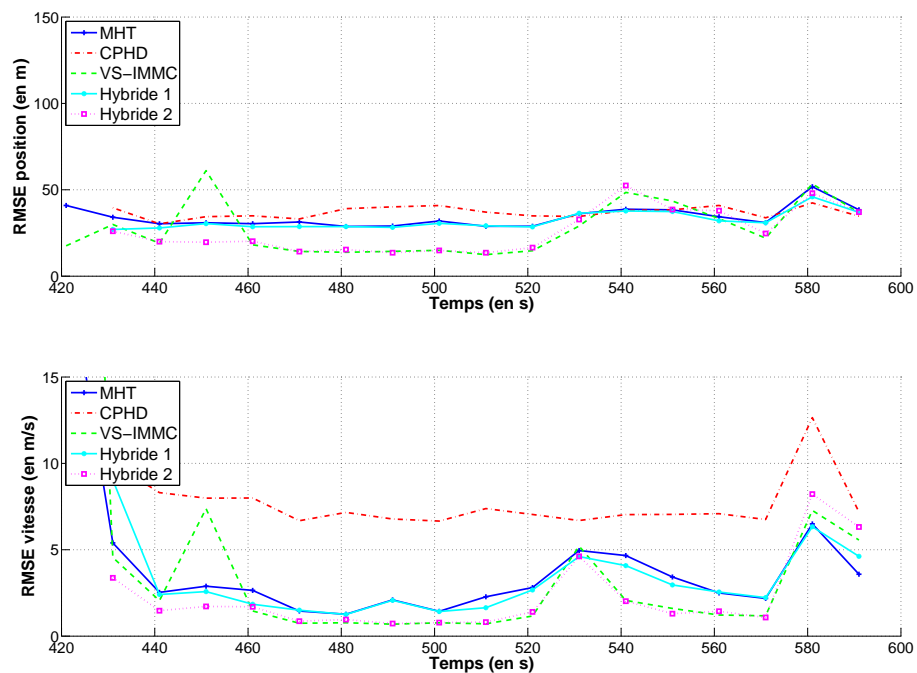


Fig. 7.56 – RMSE position et vitesse de la cible 13

Cible 14 Il s'agit d'une cible individuelle qui se met à l'arrêt avant de pouvoir s'engager sur une route. On peut globalement faire les mêmes observations que pour la cible 13 : les algorithmes utilisant le CPHD montrent des difficultés à initialiser la piste. Pendant que la cible est à l'arrêt (entre $t = 420$ s et $t = 480$ s), les performances décroissent mais cela est dû au fait que des cibles passent à proximité de celle-ci à ce moment-là, fournissant ainsi de fausses estimations.




Fig. 7.57 – Continuité de pistage de la cible 14

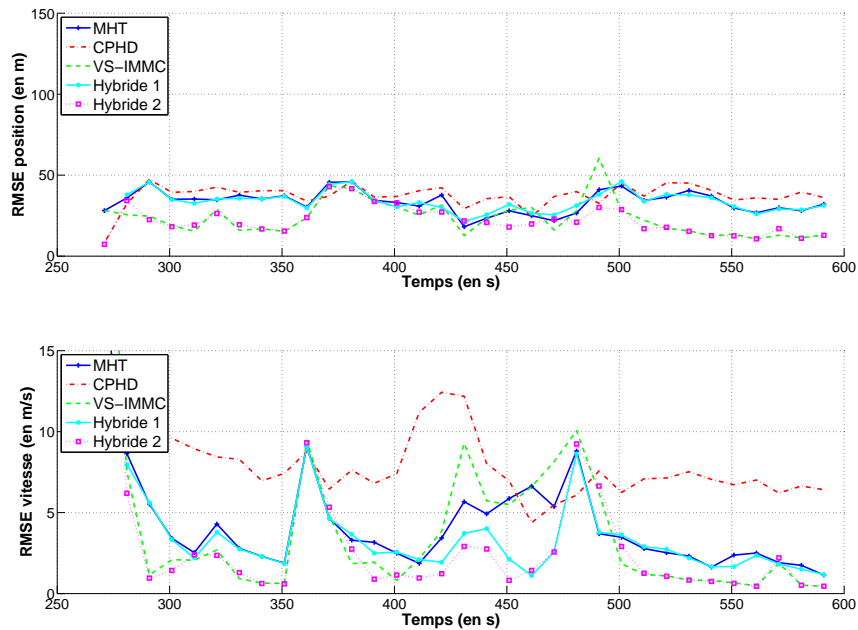


Fig. 7.58 – RMSE position et vitesse de la cible 14

7.4.2.3 Performances avec les nouvelles métriques

En conséquence des résultats globaux et individuels obtenus, les distances de Wasserstein et OSPA (*cf.* Figure 7.59) sont bien plus faibles pour les algorithmes hybrides. La distance OSPA est ainsi de l'ordre de grandeur de 40 m pour Hybridation 2, tandis qu'elle est de l'ordre de grandeur de 55 m avec le VS-IMMC-MHT. De la même façon, elle est de 55 m avec Hybridation et de 65 m avec l'IMM-MHT.




Fig. 7.59 – Cardinalité, distance de Wasserstein et OSPA

7.4.3 Résultats pour la détection de convois pour le scénario 3

La mise en œuvre du processus de détection de convoi est beaucoup plus complexe dans ce scénario plus réaliste que les autres. En effet, durant le scénario, plusieurs agrégats peuvent être détectés à la même itération, d'où la nécessité de mettre en œuvre un processus de mise en correspondance des agrégats détectés à l'itération courante avec ceux évalués à l'itération précédente (*cf.* Partie 4.6).

Nous avons appliqué le processus de détection d'agrégat (*cf.* Partie 4.1) sur la vérité terrain. En effet, le tracteur crée à plusieurs reprises des ralentissements, donc des agrégats qui ne sont pas des convois. Nous obtenons ainsi 3 agrégats tels :

- Agrégat 1 : entre $t = 31$ s et $t = 541$ s correspondant à Convoi 1
- Agrégat 2 : entre $t = 101$ s et $t = 161$ s correspondant à un premier ralentissement dû au tracteur
- Agrégat 3 : entre $t = 161$ s et $t = 581$ s correspondant à un deuxième ralentissement dû au tracteur

Par ailleurs, ces agrégats interagissent entre eux et avec les cibles indépendantes.

- Croisement de Agrégat 1 et Agrégat 3 entre $t = 341$ s et $t = 421$ s
- Croisement entre $t = 261$ s et $t = 341$ s du convoi 1 avec les cibles 2 et 10.

Nous montrons les résultats obtenus pour les différents agrégats détectés. Nous comparons les résultats obtenus avec les réseaux bayésiens et les réseaux de croyance. Par ailleurs, concernant les réseaux de croyance, nous comparons les résultats obtenus avec le modèle présentés en Figure 4.4, avec ceux du modèle présenté en Figure 5.6 dit « bis ». Dans ce modèle « bis », on ajoute la contrainte sur la vitesse que toutes les cibles considérées dans un convoi doivent évoluer dans le même sens. Le nœud S_3 est donc plus discriminatif dans les cas de croisement.

7.4.3.1 Résultats obtenus avec Agrégat 1 : vrai convoi

Nous montrons à présent les résultats obtenus en terme de détection de convoi avec l'agrégat 1 contenant 4 cibles. Dans cette partie, nous présentons les distributions de masse de croyance pour les différents nœuds. Nous montrons tout d'abord les résultats obtenus avec le réseau bayésien (Figure 7.60).

Entre $t = 81$ s et $t = 161$ s, la probabilité d'avoir un convoi de 4 cibles domine la probabilité d'avoir un convoi de 3 cibles. Elle croît vers la valeur 0.6. A partir de $t = 171$ s, la situation se complique : les probabilités d'avoir un convoi de 5, 8 et 9 cibles sont alors calculées, mais la probabilité d'avoir un convoi de 4 cibles reste cependant la plus forte. Les résultats obtenus sont corrects (même si $P\{S_9^k\}$ est assez faible ≈ 0.6). Cependant, on souhaite tout de même avoir plus d'informations sur la raison pour laquelle on calcule la probabilité d'avoir un convoi de 8 et 9 cibles. C'est pourquoi, on regarde les résultats obtenus avec les réseaux de croyance.

Les figures 7.61 et 7.62 montrent les croyances mesurées $\tilde{m}_k^{\Omega_9}(S_9)$ et estimées $\hat{m}_k^{\Omega_9}(S_9)$ pour que l'agrégat 1 détecté soit un convoi et sur le doute ($\tilde{m}_k^{\Omega_9}(\Omega_9)$ et $\hat{m}_k^{\Omega_9}(\Omega_9)$).

Les quatre courbes ont des allures très similaires : les masses de croyance d'avoir un convoi de 4 cibles dominant les masses de croyance d'avoir un convoi de 5, 8 et 9 cibles. On peut noter que l'étape d'estimation sur le nœud S_9 permet de mettre en valeur les écarts de croyance entre les différentes hypothèses pour le nombre de cibles dans le convoi. Par ailleurs, avec le modèle normal comme avec le modèle bis, la croyance mesurée d'avoir un convoi de 4 cibles tend vers la valeur 0.7, tandis qu'elle tend vers la valeur 0.8 pour les




Fig. 7.60 – Probabilité pour la variable S_9 : $P \{S_9^k\}$

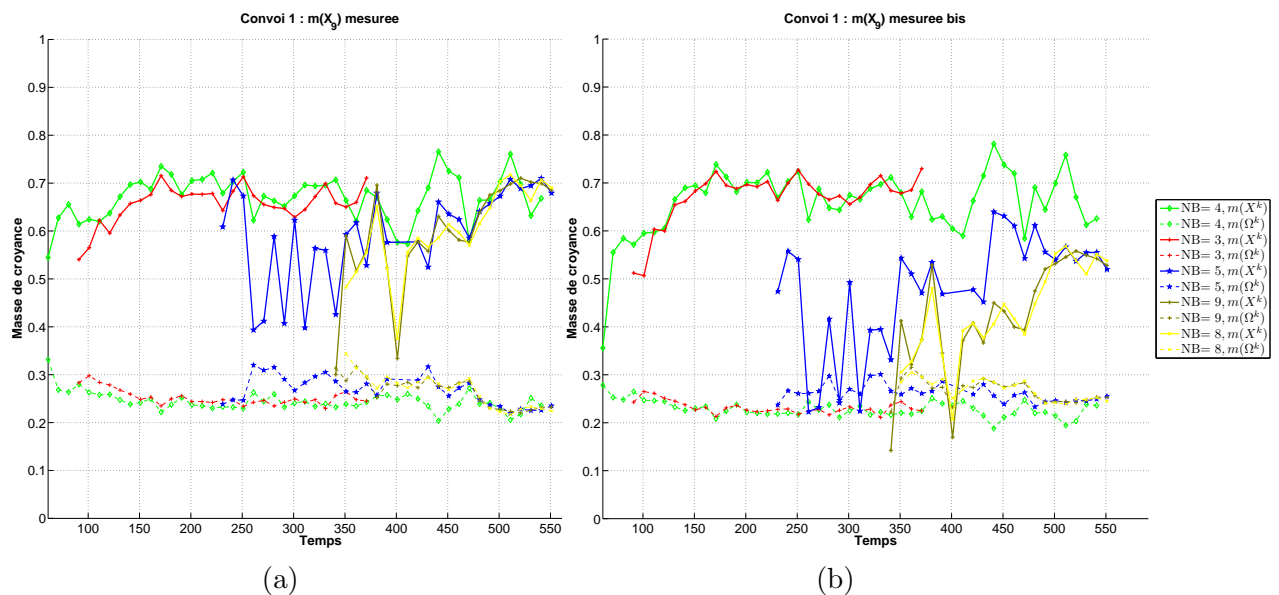


Fig. 7.61 – Masse de croyance pour la variable S_9 avec le modèle bis : $\tilde{m}_k^{\Omega_9}$ - (a) réseau classique - (b) réseau bis

croances estimées. Par contre, la croyance d’avoir un convoi de 8 cibles est plus faible avec le modèle bis qu’avec le modèle normal. Par conséquent, on discrimine mieux les différentes hypothèses pour le nombre de cibles dans le convoi.

Les courbes présentées en figure 7.63, montrent le conflit apparu lors de l’étape d’estimation sur S_9 et elles ont des allures très similaires. Au début, Le conflit est très faible jusqu’à $t = 261$ s, moment auquel le convoi est successivement croisé par deux cibles, puis par l’agrégat 2. A ce moment là, le conflit devient très fort (0.14) jusqu’à $t = 421$ s, c’est à dire la fin du croisement avec l’agrégat 2. Il augmente à nouveau entre $t = 491$ s et $t = 501$ s, ce qui correspond au moment où la cible 14 redémarre car le convoi a fini de passer. Le conflit agit donc bien ici comme un indicateur d’évènement propre au convoi et à son environnement.

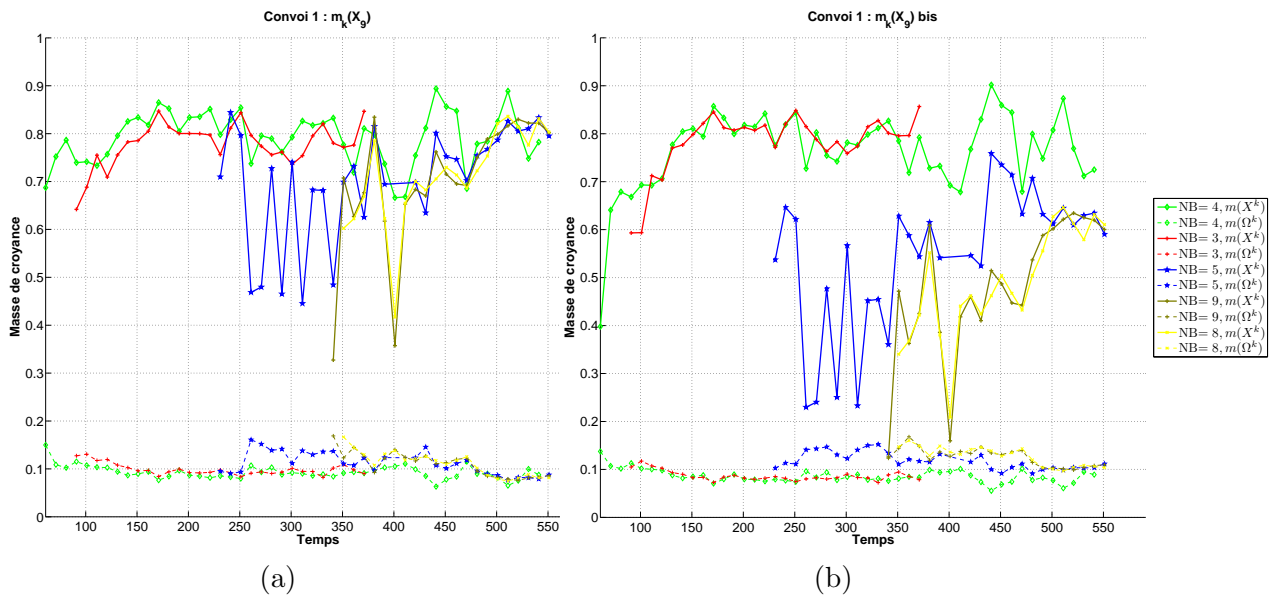


Fig. 7.62 – Masse de croyance estimée pour la variable S_9 avec le modèle bis : $\hat{m}_k^{\Omega_9}$ - (a) réseau classique - (b) réseau bis




Fig. 7.63 – Masse de croyance estimée pour la variable S_9 avec le modèle bis : \hat{m}_k^0 - (a) réseau classique - (b) réseau bis

La figure 7.64 présente la masse de croyance pour la variable S_3 qui correspond au critère vitesse. Il est intéressant ici de noter les différences entre le modèle normal et le modèle bis qui se différencient justement au niveau de ce nœud. Les croyances sur S_3 , en considérant l'hypothèse d'un convoi de 4 cibles, sont similaires et tendent vers 0.7 pour les deux modèles considérés. Cependant, pour les autres hypothèses d'avoir 5, 8 et 9 cibles, avec le modèles normal, leur croyance tend vers la croyance observée avec l'hypothèse de 4 cibles, tandis qu'elle chute complètement avec le modèle bis. Ce modèle permet donc de mieux discriminer les hypothèses lors de croisement.

La figure 7.65 présente les masses de croyance pour les variables S_4 et S_8 . Les croyances pour la variable S_4 (appartenance à la route) ont les mêmes allures pour les différentes hypothèses, ce qui est attendu puisque toutes les cibles de ce scénario évoluent sur la route. Concernant la croyance sur la variable S_8 (critère de positionnement spatial), celle-ci est

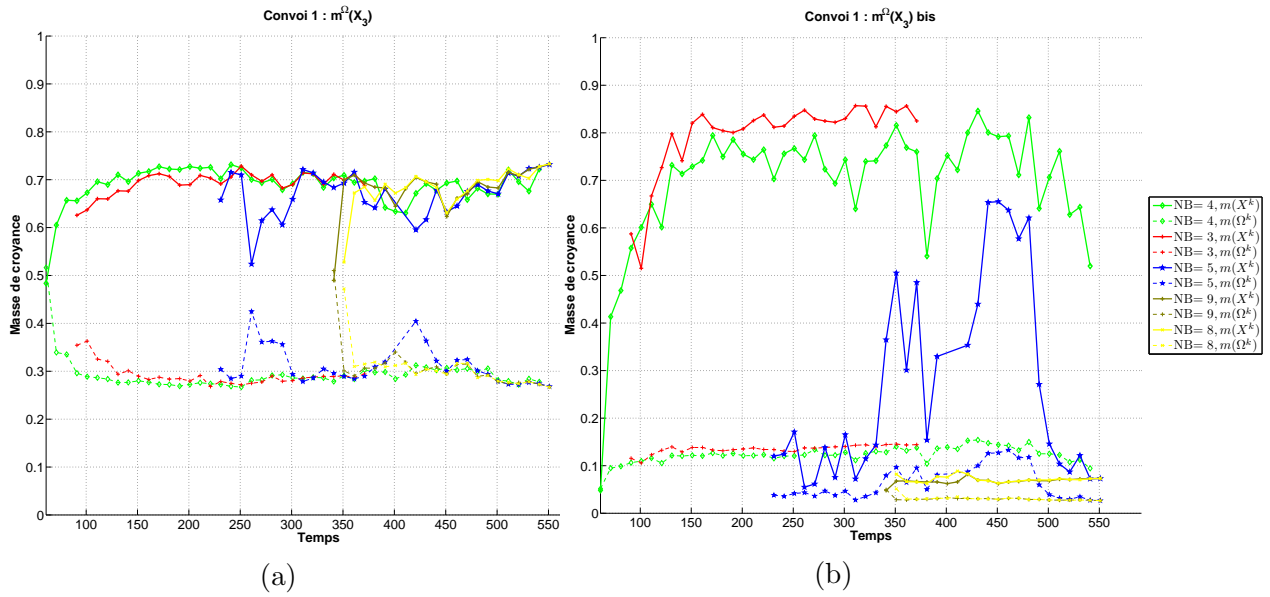


Fig. 7.64 – Masse de croyance estimée pour la variable S_3 avec le modèle bis : $\hat{m}_k^{\Omega_3}$ - (a) réseau classique - (b) réseau bis

supérieure pour l'hypothèse d'un convoi de 4 cibles, car lors des opérations de croisement les critères de positionnement spatial ne sont pas respectés par les cibles supplémentaires. Finalement, aucune information de type n'a été simulée, par conséquent, la masse de S_5 reste entièrement placée sur le doute.

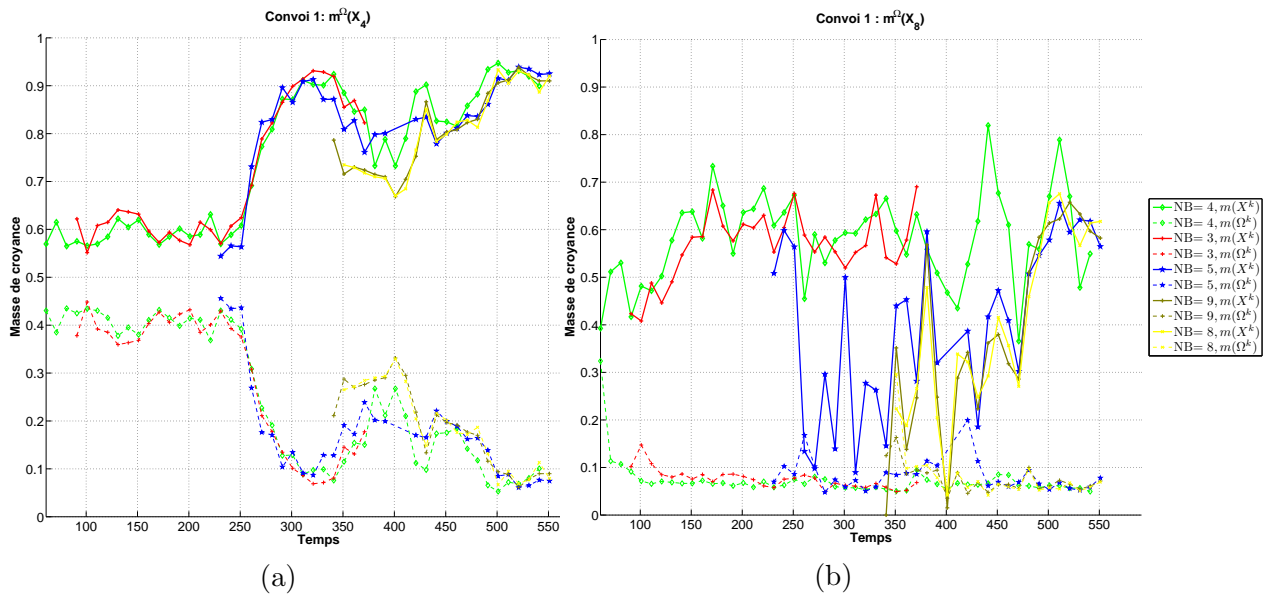


Fig. 7.65 – Masse de croyance estimée pour les variable S_4 et S_8 : - (a) $\tilde{m}_k^{\Omega_4}$ - (b) $\tilde{m}_k^{\Omega_8}$

7.4.3.2 Résultats obtenus avec Agrégat 2 : premier ralentissement dû au tracteur

La durée de détection de l'agrégat 2 est très courte (6 itérations). Au cours de cette période, les cibles 2 et 10 rejoignent le tracteur et le double successivement. Au cours de cette période, on observe que la probabilité d'avoir un convoi est faible (Figure 7.66-a), tandis que les masses de croyance mesurée (Figure 7.67-a) et estimée (Figure 7.67-b) sont faibles. Le conflit (Figure 7.66-a) est assez élevé (0.14).




Fig. 7.66 – Masse de croyance estimée pour la variable S_9 avec le modèle bis : \hat{m}_k^{Ω} - (a) réseau classique - (b) réseau bis

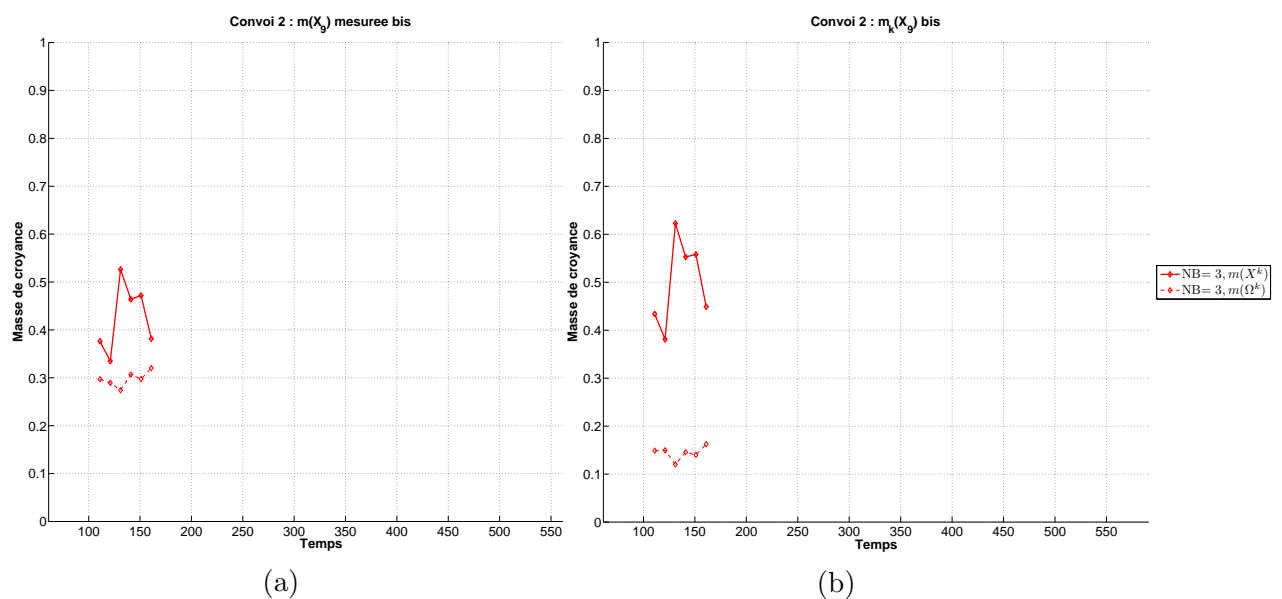


Fig. 7.67 – Masse de croyance pour la variable S_9 avec le modèle bis - (a) $\tilde{m}_k^{\Omega_9}$ - (b) $\hat{m}_k^{\Omega_9}$

7.4.3.3 Résultats obtenus avec Agrégat 3 : deuxième ralentissement du au tracteur

Les probabilités d'avoir un convoi de 3, 4, 8 ou 9 cibles (Figure 7.68) sont relativement similaires et faibles (<0.5). Le moment où la probabilité d'avoir un convoi est la plus forte se situe entre $t = 250$ s et $t = 350$ s, c'est à dire le moment précédant le croisement avec le convoi, par conséquent les cibles se rangent derrière le tracteur en attendant que le convoi passe pour pouvoir le doubler.




Fig. 7.68 – Probabilité pour la variable $S_9 : P \{S_9^k\}$

Entre les temps $t = 151$ s et $t = 251$ s, les cibles 7, 8 et 9 s'approchent du tracteur. En $t = 251$ s, elles ont rejoint le tracteur et restent bloqués bloqué derrière lui. À partir de $t = 431$ s, elles doublent successivement le tracteur. Les figures 7.69 et 7.70 montrent les croyances mesurées et estimées pour que l'agrégat 3 détecté soit un convoi. On peut faire les mêmes observations que pour les probabilités : la croyance d'avoir un convoi est assez faible. Elle est la plus forte entre $t = 250$ s et $t = 350$ s. Cependant, il est à noter qu'avec le modèle bis, on discrimine mieux les hypothèses : il est encore moins probable d'avoir un convoi de 8 ou 9 cibles.

Concernant le conflit (Figure 7.71), il est élevé pendant toute la durée de la détection. Finalement, au regard de l'ensemble des résultats obtenus, la vraisemblance pour l'agrégat 3 d'être un convoi est faible.

7.4.4 Bilan sur le scénario 3

On voit une nette différence entre les résultats obtenus pour un vrai convoi et pour des ralentissements qui créent des agrégats qui ne sont pas de convois. Même pour des agrégats détectés sur une longue période, la croyance d'avoir un convoi est plus faible. Par ailleurs, les manœuvres type croisement ne perturbent pas la détection du convoi.

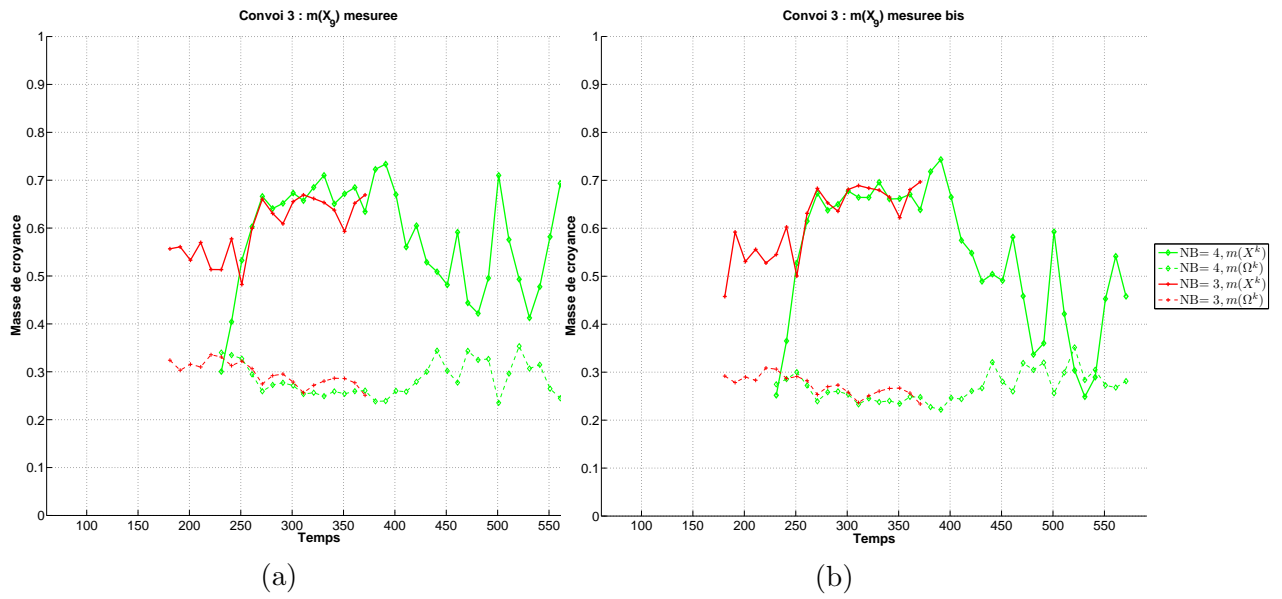


Fig. 7.69 – Masse de croyance pour la variable S_9 avec le modèle bis : $\tilde{m}_k^{\Omega_9}$ - (a) réseau classique - (b) réseau bis




Fig. 7.70 – Masse de croyance estimée pour la variable S_9 avec le modèle bis : $\hat{m}_k^{\Omega_9}$ - (a) réseau classique - (b) réseau bis




Fig. 7.71 – Masse de croyance estimée pour la variable S_9 avec le modèle bis : \hat{m}_k^0 - (a) réseau classique - (b) réseau bis

7.5 Scénario 4 : manœuvre intrinsèque dans un convoi

7.5.1 Description du scénario 4

La durée de simulation de ce scénario est de 400 secondes. Ce scénario est le scénario est très complexe dans le cadre de l'évaluation de la nature des agrégats, car une manœuvre propre au convoi y intervient : la séparation. Par ailleurs, lors de cette opération, un croisement avec une cible civile a lieu, rendant encore plus difficile l'évaluation de la situation. Pour résumer, un convoi de huit cibles évoluent sur la route principale du sud vers le nord.

- entre $t = 241$ s et $t = 291$ s, la cible 11 double le convoi.
- à partir de $t = 301$ s, le convoi se scinde en deux convois de 4 cibles ; les 4 dernières cibles du convoi bifurquent à droite.

Les caractéristiques cinématiques et de type des cibles sont décrites dans le tableau 7.12, tandis que les trajectoires sont illustrées par la figure 7.72.

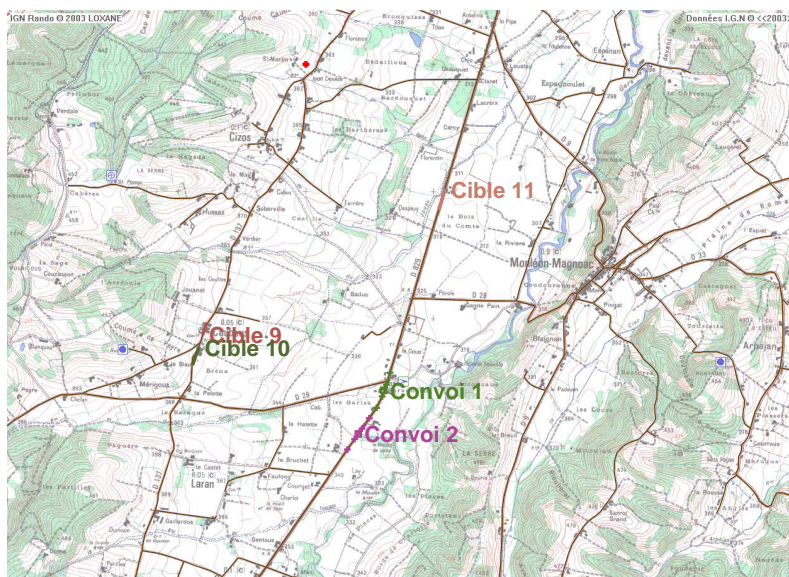


Fig. 7.72 – Trajectoire des cibles du scénario 4

	Type	t_0	t_f	v_m	Manœuvre
Convoi 1	6 chars 2 vabs $d^c = 100$ m	1 s	400 s	10 $m.s^{-1}$	-
Cible 9	Voiture	1 s	400 s	10 $m.s^{-1}$	-
Cible 10	Voiture	1 s	400 s	15 $m.s^{-1}$	-
Cible 11	Voiture	1 s	400 s	17 $m.s^{-1}$	-

Tab. 7.12 – Dynamique des cibles du scénario 4

Le cumul des plots (Figure 7.74) et la trajectoire du porteur (Figure 7.73) complètent la description du scénario 4.




Fig. 7.73 – **Scénario 4** - □ *Plot MTI avec Doppler positif* - □ *Plot MTI avec Doppler négatif* - ○ *Trajectoire du porteur* - ■ *zone d'observation*




Fig. 7.74 – **Cumul des plots MTI du scénario 4** - □ *Plot MTI avec Doppler positif* - □ *Plot MTI avec Doppler négatif* - — *Route* - ■ *zone d'observation*

7.5.2 Résultat du pistage

Dans cette partie, nous nous intéressons aux capacités d'évaluation des convois de notre module de détection de convoi à partir des pistes issues de l'algorithme Hybride 2. Par conséquent, nous présentons juste les performances obtenues pour cet algorithme avec la distance de Wassertein et OSPA (Figure 7.75)




Fig. 7.75 – Cardinalité, distance de Wasserstein et OSPA

Les distances sont faibles (10 m pour Wasserstein et 40 m pour OSPA) ce qui montre que les cibles de ce scénario sont correctement pistées.

7.5.3 Résultat pour la détection de convoi

Au début du scénario, un seul agrégat est détecté. Puis, à partir de $t = 341$ s (fin de la séparation du convoi), deux agrégats sont détectés. Nous montrons, dans cette partie, les résultats de la détection pour les deux agrégats en s'intéressant particulièrement à la période entre $t = 301$ s et $t = 341$ s, où le convoi est en cours de séparation.

La figure 7.76 montre les probabilités d'avoir les convois 1 et 2. Ces probabilités sont faibles (0.4). On peut supposer que comme le nombre de cibles dans les convois considérés est plus grand que pour les simulations précédentes, il est plus difficile de satisfaire les critères du convoi et c'est la raison pour laquelle la probabilité d'avoir un convoi de 8 cibles est faible. Même si la forme de la courbe est conforme aux formes observées pour les convois pour les scénarios étudiés précédemment, la faiblesse de la valeur de la probabilité est tout de même problématique.




Fig. 7.76 – Probabilité pour la variable $S_9 : P\{S_9^k\}$ - (a) Convoi 1 - (b) Convoi 2

Par contre, les masses de croyances (Figure 7.77) sont, elles assez fortes (≈ 0.9) pour le convoi d'avoir 8 cibles entre $t = 81$ s et $t = 301$ s et d'avoir 4 cibles entre $t = 321$ s et $t = 381$ s. On discrimine relativement bien les hypothèses 8 et 9 cibles lorsque le convoi est doublé par une cible supplémentaire (la cible 11) entre $t = 241$ s et $t = 291$ s. Les hypothèses sont moins bien discriminées que lors d'un cas de croisement comme nous l'avons vu dans le scénario 3. En effet, comme on peut le voir sur les figures 7.78 et 7.80, l'effet du doublement est moins perçu sur les variables S_3 (qui comprend le fait que toutes les cibles vont dans le même sens) et S_8 .

Néanmoins, bien que le conflit (Figure 7.79) soit faible, il est tout de même légèrement plus élevé entre $t = 241$ s et $t = 321$ s, qui correspond au doublement par la cible 11 et à la séparation.




Fig. 7.77 – Masse de croyance estimée pour la variable S_9 avec le modèle bis : $\hat{m}_k^{\Omega_9}$ - (a) Convoi 1 - (b) Convoi 2

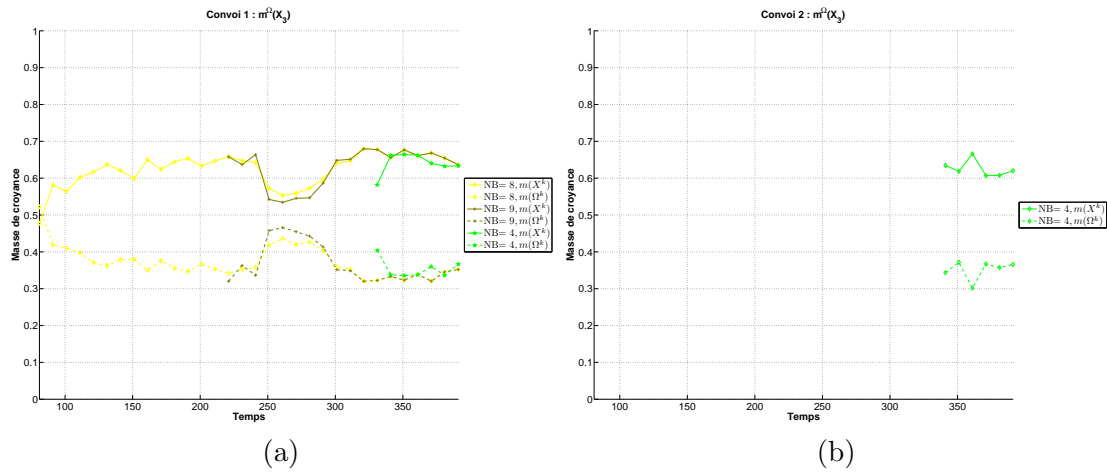


Fig. 7.78 – Masse de croyance estimée pour la variable S_3 avec le modèle bis : $\hat{m}_k^{\Omega_3}$ - (a) Convoi 1 - (b) Convoi 2




Fig. 7.79 – Masse de croyance du conflit pour la variable S_9 avec le modèle bis : $\hat{m}_k^{\Omega_9}(\emptyset)$ - (a) Convoi 1 - (b) Convoi 2




Fig. 7.80 – Masse de croyance estimée pour la variable S_8 avec le modèle bis : $\hat{m}_k^{\Omega_8}$ - (a) Convoi 1 - (b) Convoi 2

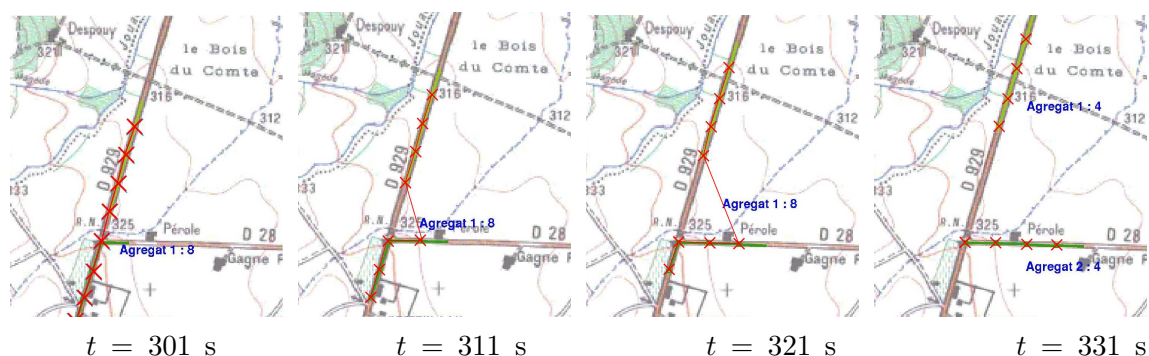


Fig. 7.81 – Zoom sur la séparation du convoi - \times position des cibles de l'agrégat - — distance entre deux cibles

Finalement, pour conclure sur le scénario 4, le cas d'une séparation de convoi est difficile à qualifier. En effet, jusqu'à ce que l'on détecte 2 agrégats au lieu d'un seul, le comportement de l'ensemble des cibles reste assimilable à celui d'un seul convoi. La figure 7.81 illustre les 4 itérations durant lesquelles le convoi se scinde en deux convois. Durant ces quatre itérations, La vitesse des cibles reste la même, donc le critère vitesse reste satisfait de la même manière que si le convoi ne se scindait pas pendant les quatre itérations de la séparation. Par ailleurs, à l'instant $t = 301$ s, un seul agrégat est détecté et le convoi amorce la séparation (la vitesse de la cible de tête du groupe qui bifurque indique un changement de direction); la longueur du convoi est la même qu'à l'itération précédente et la distance entre les cibles est constante. À l'instant $t = 311$ s, la première cible du convoi qui bifurque, a tourné, par conséquent la distance entre les cibles n'est plus tout à fait constante mais presque, car la longueur du convoi ne prend pas en compte les routes. L'instant $t = 321$ s, une deuxième cible bifurque à gauche. La longueur augmente encore, mais très peu au regard de la longueur du convoi et concernant la constance de la distance entre les cibles, une seule distance est plus grande que les autres, donc l'impact sur l'évaluation du convoi est faible. Finalement, à l'instant $t = 331$ s, deux agrégats qui sont des convois sont détectés.

7.5.3.1 Bilan

Ce quatrième scénario est très difficile à évaluer. Si les modèles proposés parviennent bien à détecter un convoi de huit cibles puis deux convois de quatre cibles. Pendant la séparation à proprement parler entre $t = 301$ s et $t = 331$ s, on ne parvient pas à détecter un changement de comportement conséquent et le conflit est relativement faible par rapport aux autres scénarios.

Il faut tout de même noter que la version probabiliste du modèle est mise en difficulté par ce scénario (la probabilité de détection est faible), tandis que la croyance conserve le même ordre de grandeur que pour les scénarios précédent.

7.6 Influence des paramètres

7.6.1 Nombre de cibles dans le convoi

Afin d'étudier l'influence du nombre de cibles dans le convoi sur les performances de pistage, nous proposons huit scénarios contenant uniquement un convoi dont le nombre de cibles varie entre 2 et 9 (Au delà de 9 cibles le MHT ne tourne plus sous matlab). La figure 7.82 présente les ARMSE position et vitesse, ainsi que les ratios de longueur des pistes moyennés pour l'ensemble des cibles.

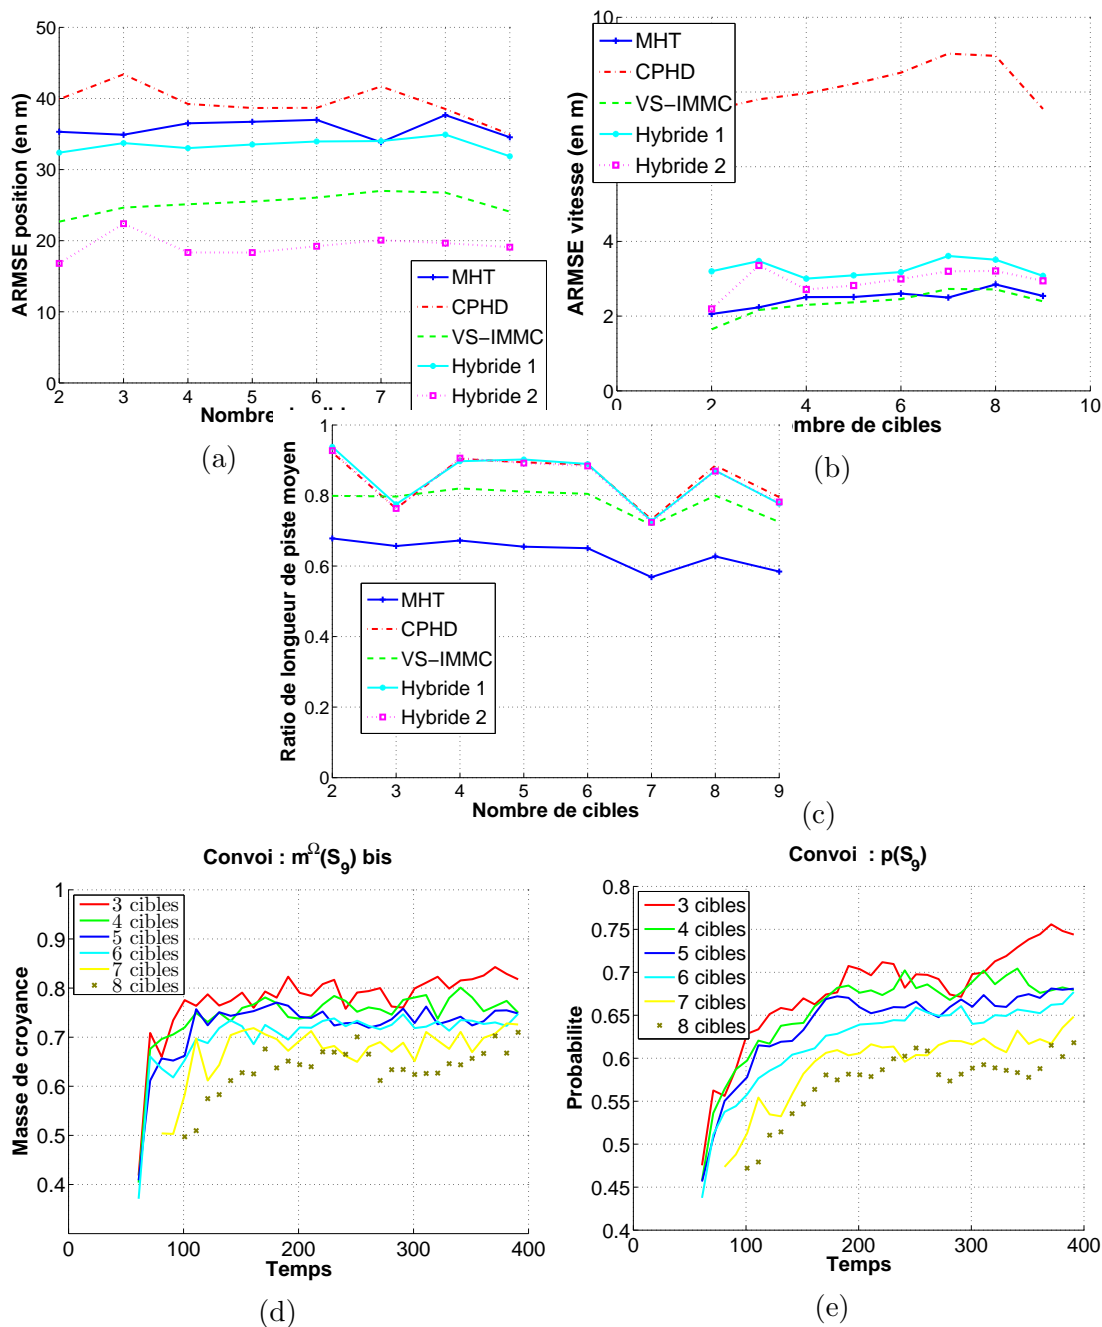


Fig. 7.82 – Performances en fonction du nombre de cibles - (a) ARMSE en position - (b) ARMSE en vitesse - (c) Ratio de longueur des pistes - (d-e) Détection de convoi

On observe que les ARMSE en position restent stables pour les algorithmes hybrides tandis qu'il croît légèrement pour le VS-IMMC-MHT et pour l'IMM-MHT. Par ailleurs, les ARMSE vitesse restent stables pour tous les algorithmes (et est toujours excessivement haut pour le GM-CPHD). Finalement, les ratios de longueur des pistes décroissent légèrement en fonction du nombre de cibles peut être légèrement plus rapidement pour les algorithmes MHT.

Concernant la détection de convoi (Figure 7.82-(d) et (e)), toutes les courbes de probabilités et de masses de croyances diminue en fonction du nombre de cibles, mais plus rapidement pour les probabilités.

7.6.2 Distance entre les cibles

Afin d'étudier l'influence de la distance entre les cibles d'un convoi sur les performances de pistage, nous proposons 4 scénarios contenant uniquement un convoi de 4 cibles dont la distance varie de 40 m à 100 m. Les figures 7.83 présentent les ARMSE moyennés en position et vitesse ainsi que les ratios de longueur de pistes pour l'ensemble des cibles. La distance entre les cibles varie entre 20 m et 100 m. Le ARMSE position reste stable tandis qu'il augmente pour les algorithmes MHT lorsque la distance entre les véhicules du convoi croît. Les ARMSE vitesse restent stables pour les 5 algorithmes. Finalement, concernant le ratio de longueur des pistes, il est stable pour les algorithmes hybrides et augmente avec la distance pour les algorithmes MHT. Il semble que le ratio de longueur de piste du VS-IMMC-MHT tend vers celui de Hybridation 2, ce qui sous entend qu'en l'absence d'agrégat, les performances de Hybridation 2 tendent vers celles du VS-IMMC-MHT. Cela prouve que l'algorithme hybride pallie bien les difficultés liées au pistage de cibles proches. Nous aurions pu vérifier cette hypothèse en faisant varier encore plus la distance entre les cibles.

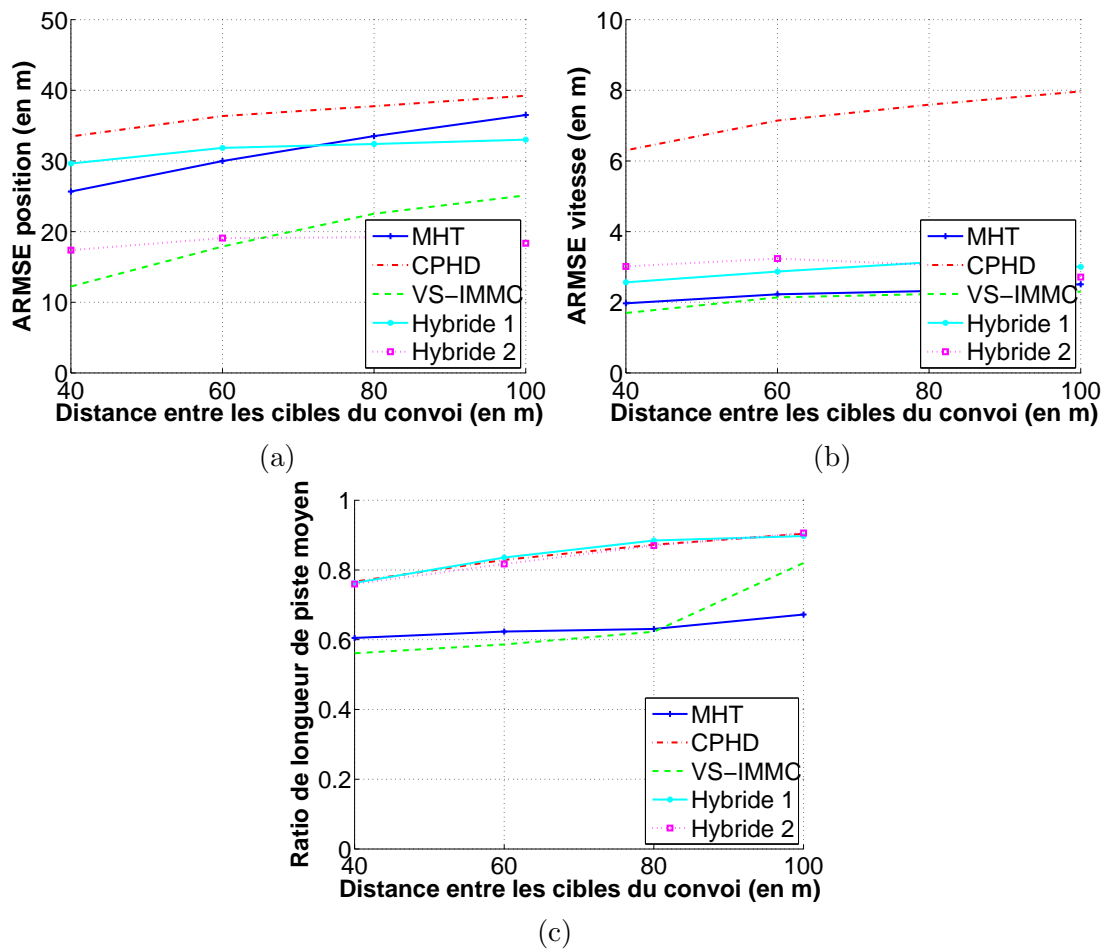


Fig. 7.83 – Performances en fonction de la distance entre les cibles - (a) ARMSE en position - (b) ARMSE en vitesse - (c) Ratio de longueur des pistes

7.6.3 Densité de fausses alarmes

La figure 7.84 présente les performances obtenues pour différentes valeurs de densité de fausses alarmes telles que les nombres moyens de fausses alarmes à chaque itération sont : $n_{fa}^1 = 6$, $n_{fa}^2 = 8$, $n_{fa}^3 = 10$, $n_{fa}^4 = 25$. Les ARMSE positions et vitesse ainsi que le ratio

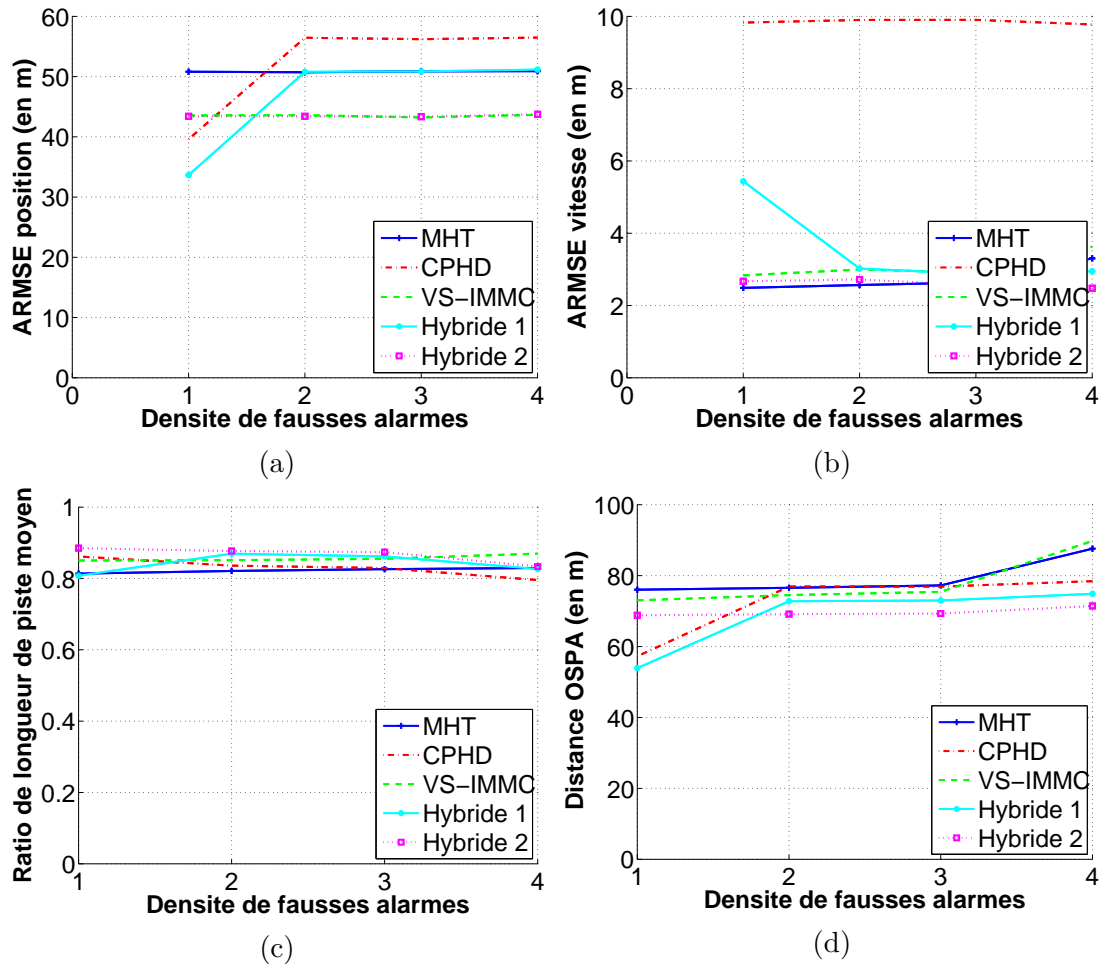


Fig. 7.84 – Performances en fonction de la densité de fausses alarmes - (a) ARMSE en position - (b) ARMSE en vitesse - (c) Ratio de longueur des pistes - (d) distance OSPA

de longueur des pistes restent constant tandis que le ratio de fausses alarmes augmente. Par ailleurs, on aurait pu s'attendre à voir augmenter la distance OSPA moyenne étant donné que le taux de fausses pistes devrait augmenter avec le taux de fausses alarmes. Il n'en est rien.

7.6.4 Bruit de mesures

Nous reprenons le cas du convoi de 6 cibles présenté dans le scénario 2 (*cf.* Partie 7.3) et étudions à présent l'influence du bruit de mesures. Les bruits de mesures utilisés pour les simulations précédentes (*cf.* Tableau 7.1) étaient relativement élevés. Nous allons à présent présenter les résultats pour la détection de convoi pour un bruit de mesure plus faibles. Ainsi, nous utilisons $\sigma_r = 15$ m, $\sigma_\phi = 6.10^{-4}$ et $\sigma_{\dot{\phi}} = 1m.s^{-1}$. La figure 7.85 présente les résultats pour la détection du convoi 1. Ces résultats sont à comparer à ceux précédemment exposés sur les figures 7.38 à 7.39.

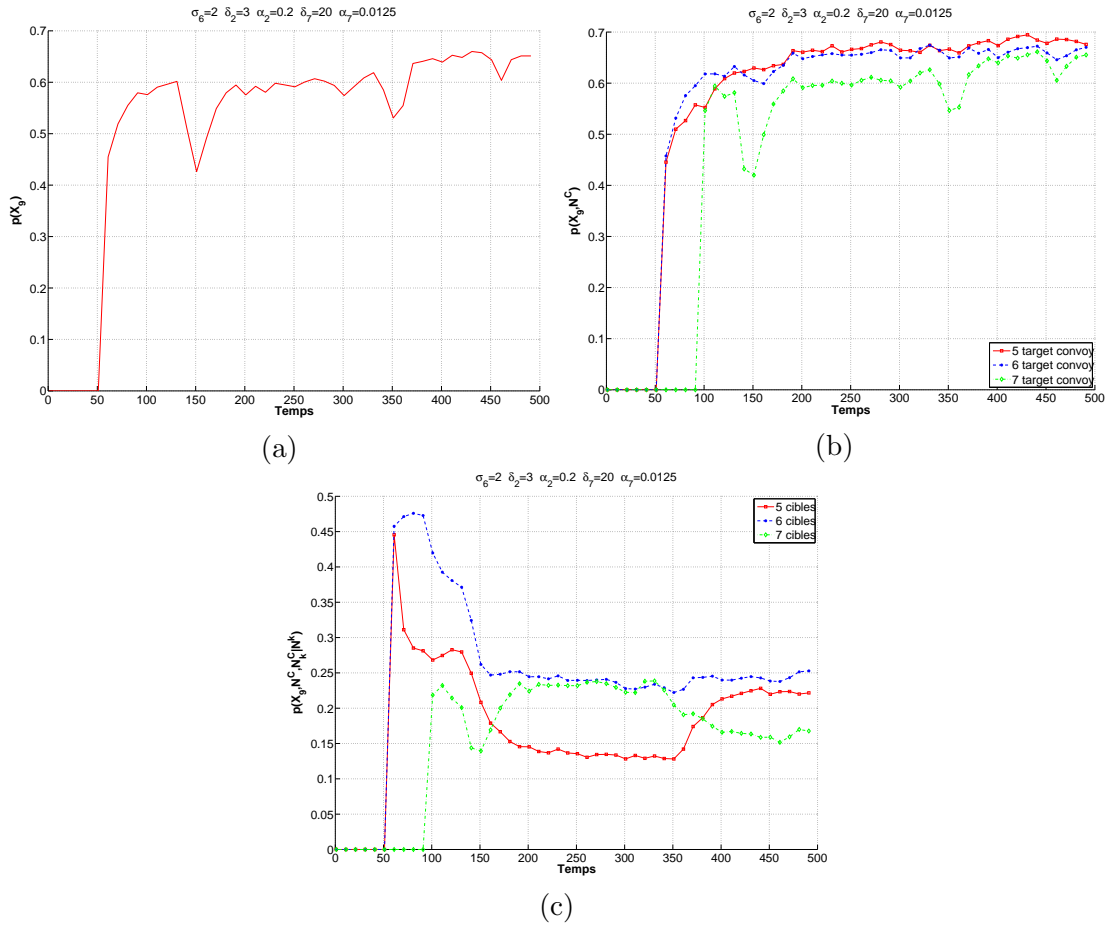


Fig. 7.85 – Performances en fonction du bruit de mesure - (a) $P\{S_9^k | N_{k_0:k}\}$ - (b) $P\{S_9^k | N_{k_0:k}^A, N_i^C\}$ - (c) $P\{N_i^C | N_{k_0:k}^A, \hat{N}_k^A\}$

On observe qu'avec le bruit de mesure dit « moyen », la probabilité de détection du convoi 1 tend vers la valeur 0.6, tandis qu'avec le bruit de mesure dit « faible », elle tend avec 0.65 avec les mêmes coefficients de transformation des données en probabilités.

7.6.5 Paramètres de transformation des données en probabilités

Nous reprenons le cas du convoi de 6 cibles présentés dans le scénario 2 (*cf.* Partie 7.3) et étudions à présent l'influence des paramètres de transformation des données en probabilités. Nous proposons un deuxième jeu de paramètres plus discriminatifs (les probabilités sur les différents nœuds tendent plus facilement vers 0 :

Notation	Valeur	Nom
Paramètres du graphe flou de la variable S_2	(0.8, 0.09)	(Δ_2, α_2)
Paramètres du graphe flou de la variable S_7	(15, 0.014)	(Δ_7, α_7)
Paramètre du graphe flou de la variable S_6	1	σ_6
Variance de la gaussienne pour le calcul de $P \left\{ \hat{N}_k^A N_{k-1}^A \right\}$	2	σ_N
Paramètres du graphe flou de la variable N^A	(0.5, 0.05)	(Δ_N, α_N)

Tab. 7.13 – Jeu de paramètres 2 pour la mise en œuvre des réseaux bayésiens

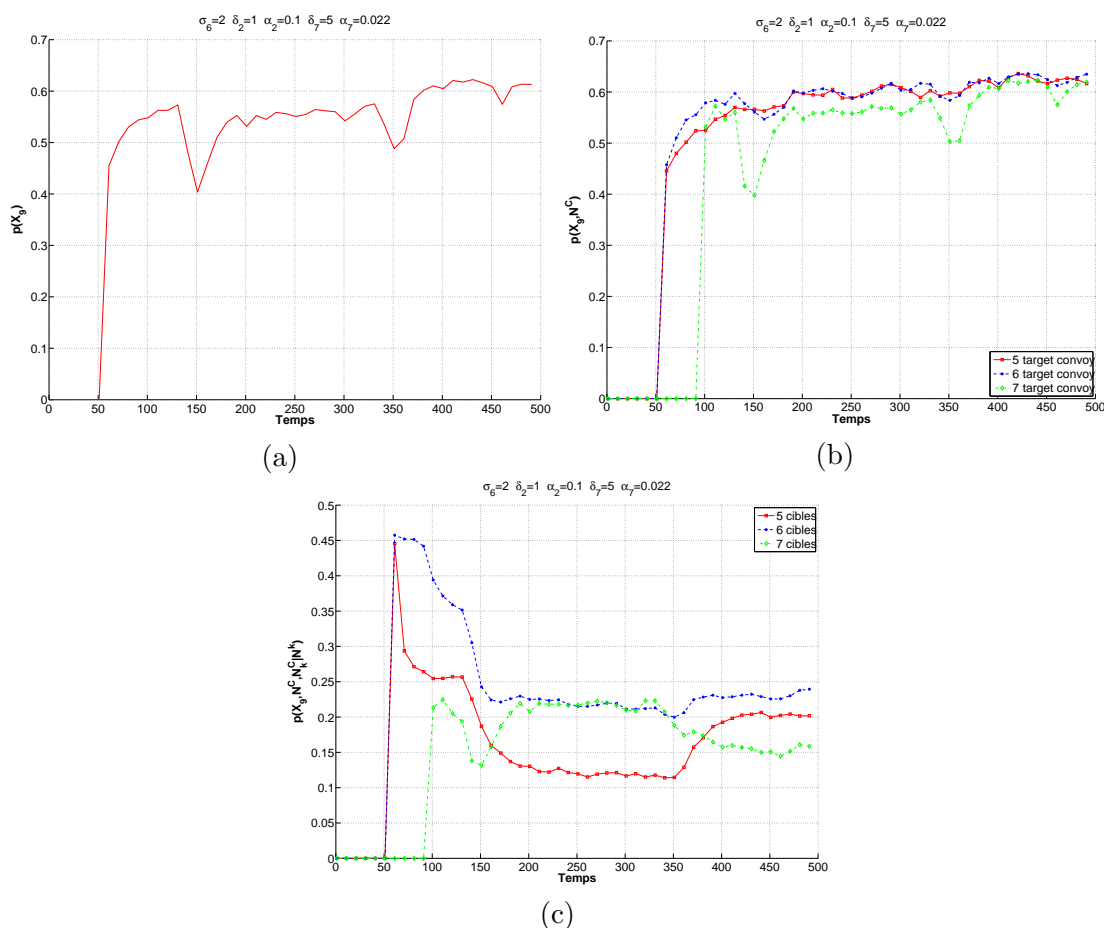


Fig. 7.86 – Probabilité d'avoir un convoi avec le jeu de paramètres 1 - (a) $P \left\{ S_9^k | N_{k_0:k} \right\}$ - (b) $P \left\{ S_9^k | N_{k_0:k}^A, N_i^C \right\}$ - (c) $P \left\{ N_i^C | N_{k_0:k}^A, \hat{N}_k^A \right\}$

Avec les paramètres plus discriminatifs, la probabilité d'avoir un convoi conserve la même allure, mais elle tend vers une valeur plus faible (< 0.6). Cependant, l'avantage est

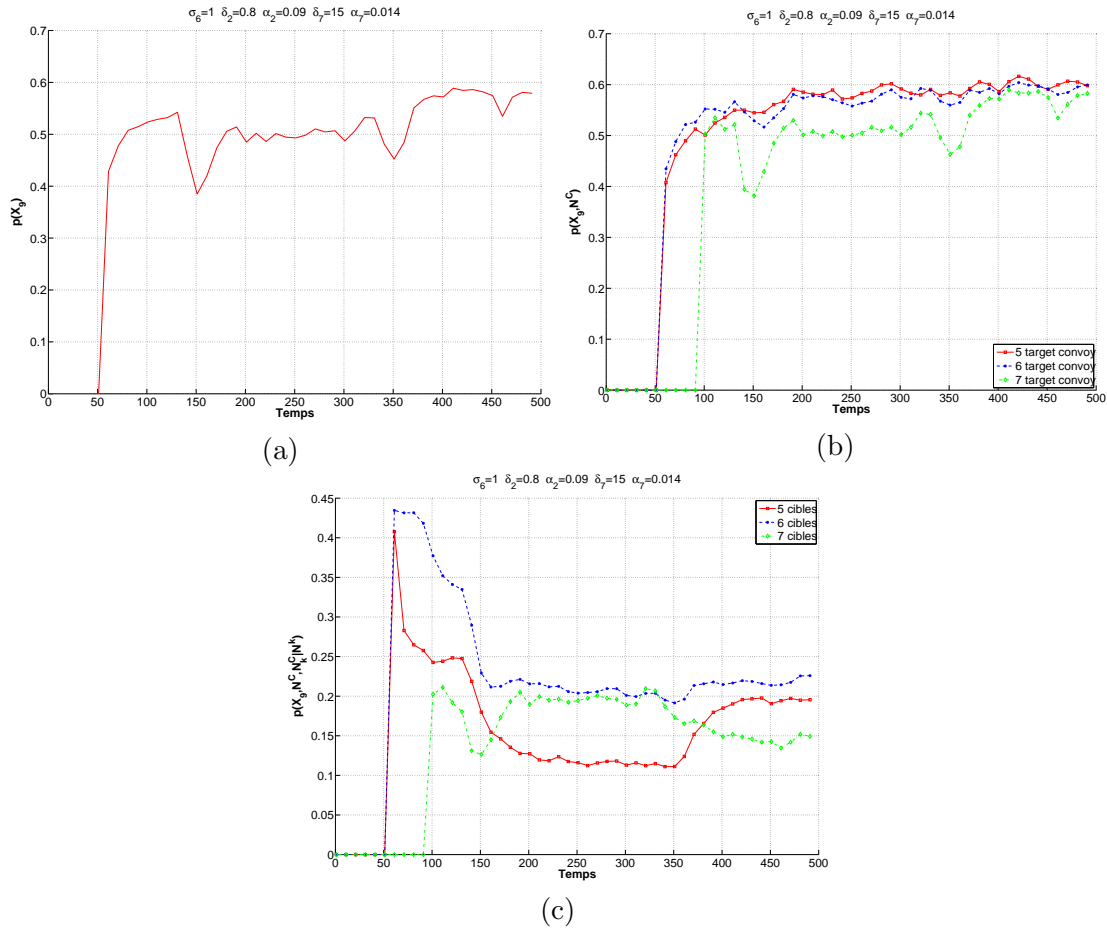


Fig. 7.87 – Probabilité d’avoir un convoi avec le jeu de paramètres 2 - (a) $P\{S_9^k | N_{k_0:k}\}$ - (b) $P\{S_9^k | N_{k_0:k}^A, N_i^C\}$ - (c) $P\{N_i^C | N_{k_0:k}^A, N_k^A\}$

que l’on discrimine mieux les probabilités d’avoir un convoi de 6 et 7 cibles.

7.6.6 Paramètres d’estimation du nombre de cibles

La figure 7.39 présentait les probabilités d’avoir $\{N^C\}_{V_i}$. Nous faisons à présent varier les paramètres $(\sigma_N, \Delta_N, \alpha_N)$ pour le scénario 2 tels que :

- $\sigma_N = 3$
- $\Delta_N = 0.5$
- $\alpha_N = 0.2$

Ces nouveaux paramètres sont choisis de manière à pénaliser de manière plus importante les différences de cardinalité entre le nombre de cibles considéré N_i^C et N_k^A . Effectivement, on observe que les hypothèses 5 et 6 cibles dans le convoi sont mieux discriminés après la phase de dépassement. Néanmoins, la probabilité d’avoir 7 cibles est plus forte pendant la phase de dépassement. Cela n’est pas forcément gênant, puisque ces deux hypothèses sont discriminées au niveau du calcul de $P\{S_9^k | N_{k_0:k}^A, N_i^C\}$ (cf. Figure 7.38).




Fig. 7.88 – Probabilité de détection du convoi 1 de taille N^C

7.6.6.1 Bilan

Nous avons testé les limites de notre approche pour le pistage et la détection de convoi en faisant varier un grand nombre de paramètres. Pour la partie pistage, on tend vers des conclusions similaires à celle obtenues avec les scénarios. Ainsi, les performances des algorithmes hybrides en terme de précision de l'estimation tendent vers les performances du MHT avec ou sans contrainte. Tandis que si les cibles sont distantes, les performances en terme de détection pour le VS-IMMC-MHT tendent vers celles du filtre CPHD. Nous avons donc correctement identifié les points forts de ces algorithmes et nous avons su les exploiter dans l'hybridation.

Concernant la détection de convoi, les limites ont surtout été testées grâce aux différents scénarios. Cependant, il ressort que le modèle reste stable lorsque l'on fait varier les bruits de mesure et les paramètres de transformation des données en probabilités.

Conclusion

Les résultats obtenus avec les différents scénarios sont cohérents aussi bien pour la partie pistage que pour la partie détection de convoi. Ainsi, pour la partie pistage nous avons élaboré un algorithme hybride de pistage multicible qui piste aussi bien les cibles proches que les cibles distantes, contrairement aux approches usuelles. Le principe de l'hybridation est le suivant. Le filtre CPHD, grâce à une estimation très fiable du nombre de cibles sur la zone d'observation et grâce à une technique de labellisation efficace, est très performant pour détecter les cibles, tandis que l'IMM-MHT, avec ou sans contrainte selon les conditions, améliore l'estimation de l'état des cibles. Finalement, le schéma de principe de l'algorithme hybride peut être ramené au schéma de principe présenté en figure 7.89.

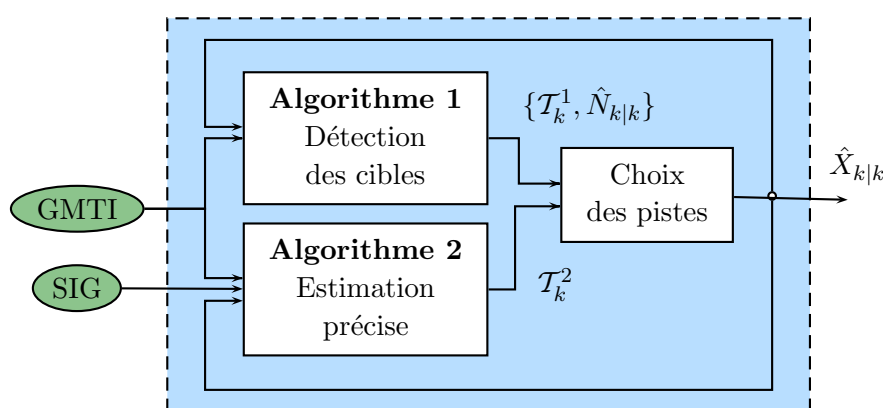


Fig. 7.89 – Principe général de l'hybridation

L'algorithme 1 a pour caractéristique de détecter avec précision et rapidité les pistes. L'algorithme 2 peut être plus complexe, il utilise tous les moyens disponibles (coordonnées des routes, type des cibles, approche multi-modèles...) pour obtenir une estimation de l'état la plus précise possible. Dans des conditions différentes (équation de mouvement non linéaire par exemple), on pourrait imaginer utiliser un tout autre algorithme que le MHT pour l'Algorithme 2 (inspiré du filtrage particulaire par exemple).

Concernant la partie détection de convoi, la variété et le niveau de difficulté des scénarios proposés nous permet de juger de la robustesse et de la pertinence du modèle élaboré. Ainsi, dans des scénarios simples, on parvient à détecter des convois avec une probabilité forte et même à évaluer avec précision le nombre de cibles le composant. Pour des scénarios plus complexes (grand nombre de cibles dans le convoi, manœuvres internes, interaction avec d'autres cibles), la valeur des probabilités de détection diminue, tandis qu'avec les TBM, les croyances restent fortes. Par ailleurs, nous exploitons avec ce formalisme, le conflit qui apparaît sur la croyance d'avoir un convoi. Ce conflit agit comme d'un indicateur de manœuvres. Un dernier travail consisterait à utiliser le conflit sur les nœuds intermédiaires afin de qualifier les manœuvres.

Pour finir, le modèle est robuste aux « faux convois ».

Résultats sur données réelles

Pour des raisons de confidentialité, ce rapport n'est pas attaché au manuscrit de thèse.
Il est référencé sous le titre . . .

Conclusion générale et perspectives

Dans le domaine du traitement de l'information, la multiplication des sources de données soulèvent le problème de la pertinence de l'information. Ainsi, une part importante du problème est l'élévation du niveau sémantique d'une donnée fournie à un opérateur : on souhaite, à partir d'une donnée numérique, produire une information parlante pour un être humain. Dans le cadre de la surveillance du champ de bataille, la problématique est identique et c'est la raison pour laquelle nous nous sommes intéressés à la notion d'évaluation de situation. Dans ce cadre, nous avons utilisé les données issues de capteurs GMTI, SAR et vidéo, ainsi que les SIG afin de mettre en œuvre l'évaluation de la situation tactique. Partant du modèle JDL, nous proposons dans cette thèse de faire une évaluation globale des entités présentes et de dégager, à travers l'étude des relations existant entre elles et avec leur environnement, des objets d'intérêt. L'évaluation de ces objets d'intérêt au cours du temps permet de faire une analyse plus pertinente et plus fine de la situation sur la zone observée. Un objet d'intérêt a particulièrement retenu notre attention : il s'agit du convoi. En effet, celui-ci est d'un haut intérêt stratégique car il reflète un déplacement opérationnel d'hommes et de matériels. Cependant, de par la proximité des cibles qui le composent, il est très difficile à détecter et à caractériser. L'idée de cette thèse est donc de développer une technique pour l'évaluation globale de la situation ainsi que la détection de convoi et de généraliser la méthode de détection à n'importe quel type d'objets d'intérêt.

Dans le cadre de l'évaluation globale de la situation, l'utilisation d'une technique de trajectographie à partir des données issues de capteurs GMTI est incontournable, car c'est l'un des seuls capteurs aéroportés capable de couvrir une très grande zone d'observation quelles que soient les conditions climatiques. Or, comme nous l'avons montré à travers une étude comparative théorique des techniques usuelles de pistage, ces dernières montrent des faiblesses concernant le pistage de cibles proches, à l'exception du filtre CPHD. C'est pourquoi nous avons développé un algorithme hybride CPHD-MHT, afin de combiner les avantages de ces techniques usuelles (à savoir : capacité de pistage des cibles proches - précision de l'estimation de l'état) en limitant leurs inconvénients (estimation de la vitesse des cibles - dégradation des performances lorsque les cibles sont proches). Par ailleurs, afin d'améliorer la précision dans l'estimation de l'état des cibles, nous avons introduit les coordonnées des routes contenues dans les SIG, à travers l'utilisation, dans l'algorithme hybride, du VS-IMMC-MHT. Il s'agit d'un algorithme dérivé de l'IMM-MHT qui contraint le pistage de cibles manœuvrantes sur le réseau routier. Les points forts de cet algorithme sont la prise en compte de modèles *on-road* et *off-road* : il est ainsi capable de pister les cibles sur et en-dehors du réseau routier. Par ailleurs, lorsqu'une cible arrive à proximité d'une intersection, il est capable de différer le moment de la prise de décision grâce à un test séquentiel de Wald. Ainsi, grâce aux différentes informations disponibles, nous sommes

en mesure de pister avec précision un grand nombre de cibles, que celles-ci soient proches ou distantes les unes des autres et qu'elles évoluent sur le réseau routier ou non.

Dans le cadre de la détection de convois, nous avons développé une méthode de détection originale au vue de la littérature. L'idée principale est de dire que la précision du pistage est suffisante pour évaluer le comportement d'un agrégat par l'étude du comportement individuel des cibles. Ainsi, nous avons développé un modèle graphique prenant en compte un maximum des caractéristiques des cibles constituant un convoi dans le but d'évaluer si l'agrégat détecté à partir des pistes est un convoi ou non. Le choix des modèles graphiques a été fait suite à une étude approfondie des techniques de modélisation et de représentation de l'incertain. Nous avons constaté que, par la multiplicité et l'hétérogénéité des contraintes liées à l'objet d'intérêt convoi, les modèles graphiques étaient très adaptés. Par ailleurs, nous avons développé ce modèle sous deux formalismes. Tout d'abord dans un cadre probabilistes, en effet, les probabilités constituent une représentation de l'information incontournable. À ce stade, nous sommes capables de détecter et de caractériser des convois (et non pas un ensemble de véhicules ponctuellement proches). Cependant, cette approche montre des faiblesses lorsque le convoi manœuvre, c'est pourquoi, nous nous sommes intéressés aux réseaux crédibilistes afin d'étudier le doute et le conflit sur les différents nœuds du réseau afin de mieux évaluer les manœuvres intrinsèques et extrinsèques du convoi.

Il faut noter que l'utilisation des modèles graphiques n'a pas constitué qu'un simple transfert de technologie. Nous avons développé quelques outils théoriques à travers l'utilisation des réseaux crédibilistes. Tout d'abord, nous avons formalisé le processus d'inférence d'un nœud à l'autre. Par ailleurs, nous avons pour la première fois utilisé un filtre temporel crédibiliste afin de rendre notre réseau dynamique.

Au cours de cette thèse, nous avons choisi de développer un algorithme hybride de pistage multicible, développé un modèle de réseau bayésien dynamique et introduit le modèle des croyances transférable dans cette dernière approche. Cependant, de nombreuses perspectives restent à explorer.

Perspectives

Perspectives pour le pistage multicible

Au niveau du pistage multicible, nous avons développé un algorithme hybride. Une autre alternative aurait été de pallier directement les faiblesses de l'estimation de l'état du GM-CPHD. Par exemple,

- amélioration de l'estimation de la vitesse des cibles en appliquant un filtre de Kalman *a posteriori*,
- amélioration de l'estimation de la vitesse des cibles en prenant en compte de l'effet Doppler dans le processus de pistage,
- ajout des contraintes routière à la manière du VS IMMC MHT en considérant un test de Wald pour les intersections et les modèles on-road/off-road pour pister les cibles sur et en dehors du réseau routier,
- trouver un développement théorique pour le GM-CPHD pour s'affranchir de l'hypothèse de constance de la probabilité de détection et de la probabilité de survie pour le rendre compatible avec la problématique de masques de terrain.

Par ailleurs, nous aurions pu améliorer l'évaluation des performances de notre algorithme en simulant le phénomène des cibles non-résolues. Ces dernières sont des objets qui sont tellement proches au regard de la résolution du capteur, qu'une seule mesure est fournie. Dans le cadre de l'évaluation de convois, les résultats auraient été plus pertinents. Cela dit, les résultats obtenus avec les données réelles ont été conformes à ceux obtenus avec les données simulées. Une autre petite amélioration serait de prendre mieux en charge les cibles qui sortent de la zone d'observation à la manière du traitement réalisé avec les masques de terrain.

Pour finir sur le pistage, un important travail reste à accomplir afin d'adapter l'algorithme au cas multicapteur.

Perspectives pour la détection d'objets d'intérêt

Concernant la détection d'objets d'intérêt, il faudrait généraliser la méthode de détection de convois, telle qu'elle est représentée en figure 9.1 à n'importe quel type d'objets d'intérêt, connu ou inconnu. Une méthode envisageable serait de faire de l'apprentissage sur la structure du réseau. Cette étape d'apprentissage ne pourra se faire sans avoir l'avis des opérationnels. Par ailleurs, les modèles pourraient encore être enrichis par l'utilisation d'autres types de données comme les données ESM, infra-rouge ou encore les renseignements d'origine humaine.




Fig. 9.1 – Schéma du processus de détection de convoi

Cette méthode pourrait être généralisée comme présenté sur la figure 9.2. À partir des informations contextuelles et issues des capteurs, des étapes de traitement sont réalisées afin de dégager des informations pertinentes (ou contraintes). Ces attributs de contrainte sont alors testés sur des modèles connus d'objets d'intérêt, notés OI2, OI3, ... comme le convoi. La structure de ces objets d'intérêt est toujours la même : ainsi les différentes contraintes aboutissent à un seul nœud racine qui évalue si l'objet détecté est un des objets déjà connus. Si de manière récurrente, un objet ne correspond à aucun des objets d'intérêt connus, il peut être envisageable, en collaboration avec des opérationnels, de lancer un apprentissage pour modéliser un nouvel objet. Comme on suppose que l'objet d'intérêt a une structure d'arbre (toutes les contraintes aboutissent sur le nœud OI), l'apprentissage peut se faire à deux niveaux. D'une part, au niveau du choix des contraintes dont dépend l'objet, l'opérateur peut faire apprendre au système de nouvelles contraintes ou en utiliser des connues. D'autre part, une fois ces contraintes identifiées, l'apprentissage pourrait avoir lieu dans la pondération des différents nœuds parents.

Ainsi, pour la suite de ces travaux, il faut concevoir un système de fusion de données multicapteur dans lequel l'intégration de l'avis d'experts sera primordiale. Par ailleurs, l'importance et l'impact des décisions qui sont prises quant à une éventuelle réponse à une

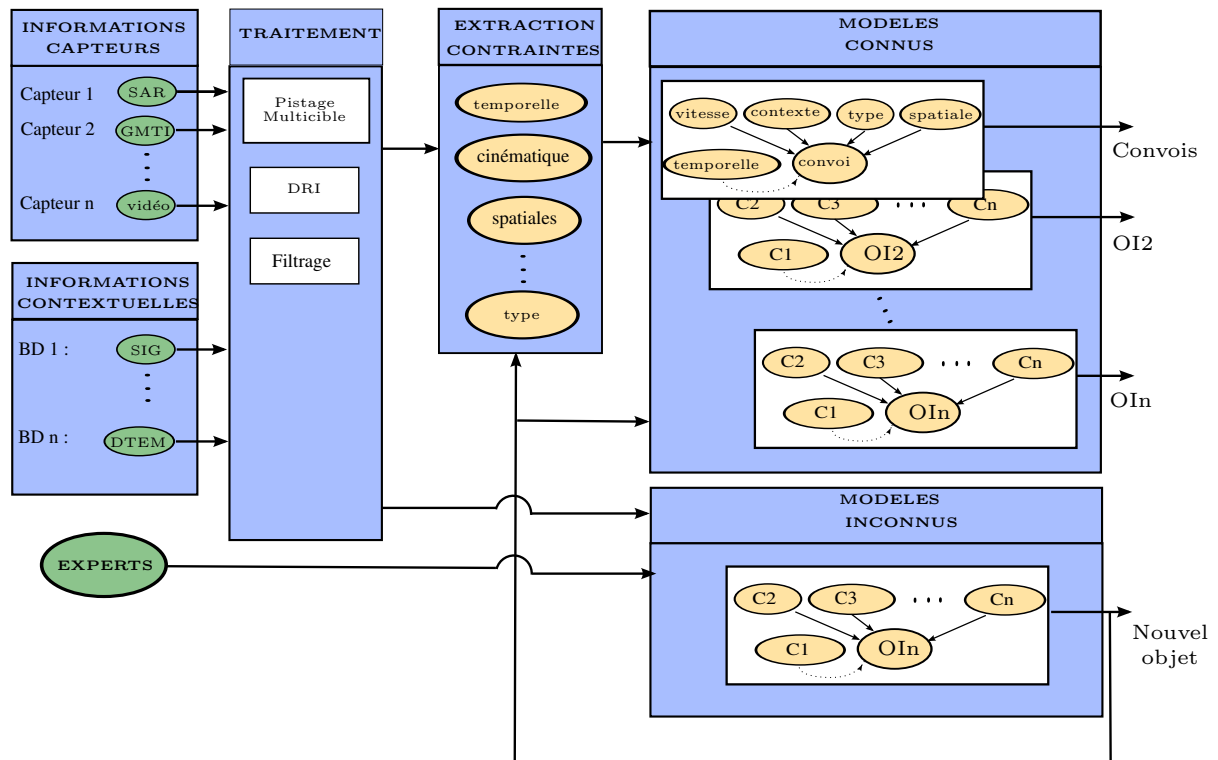


Fig. 9.2 – Schéma du processus de détection d'objets d'intérêt - *OI1* : *Objet d'Intérêt 1* - *C1* : *Contrainte 1*, *BD1* : *Base de Données 1*

menace est tellement critique qu'ils justifient complètement l'intervention humaine et le fait qu'on ne puisse pas complètement automatiser le système d'évaluation de situations.

Perspectives pour les réseaux crédibilistes

Les dernières perspectives concernent les réseaux crédibilistes. Il reste beaucoup de travail théorique dans ce domaine. Par exemple, dans notre application, l'utilisation des fonctions de croyance est fortement limitée par la relation (5.22) de transformation des données en masses de croyance. Il pourrait être judicieux d'introduire l'incertitude des données dans les masses de croyance et de pondérer la masse de croyance accordée au doute par l'incertitude des données.

Par ailleurs, le mécanisme de propagation de l'information à travers le réseau est limité à des réseaux très simples. Il serait donc très intéressant d'adapter le mécanisme d'inférence JLO [Jensen 1990] aux fonctions de croyance.

Les réseaux bayésiens

Sommaire

A.1 Généralités sur les réseaux bayésiens	242
A.1.1 Introduction	242
A.1.2 Définition	242
A.1.3 Structure	242
A.1.4 La d-séparation : définition et propriété	243
A.1.5 Construction d'un réseau bayésien et apprentissage	244
A.2 Inférence bayésienne	245
A.2.1 L'algorithme JLO	245
A.2.2 L'algorithme EM	247
A.3 Les réseaux bayésiens dynamiques	248
A.4 Les modèles de Markov cachés	249
A.4.1 Les chaînes de Markov du 1 ordre	249
A.4.2 Les modèles de Markov cachés	249
A.4.3 Applications possibles pour les HMM	250

Introduction

Les réseaux bayésiens représentent l'union entre les la théorie des probabilités et la théorie des graphes. Le graphe permet de représenter les relations de causalité existant entre les variables d'un système et les probabilités jointes permettent de quantifier cette relation. Initialement introduit par Pearl en 1988 (*cf.* [Pearl 1988]), l'utilisation première des réseaux bayésiens est de calculer la probabilité d'une hypothèse connaissant certaines observations. Mais de par leurs nombreuses extensions, ils peuvent également être très utile pour déterminer la valeur la plus probable d'une variable, connaître la cause la plus probable d'une information donnée ou analyser la sensibilité du système par rapport à une information.

De par ce fait, les réseaux bayésiens trouvent de nombreuses applications dans les domaines suivants :

Santé : en tant qu'aide au diagnostic par exemple ([Djebbar 2006],[Bellot 2002]) ou dans la recherche génétique ([Murphy 1999])

Industrie : pour le contrôle de systèmes autonomes, ou encore la reconnaissance de paroles([Zweig 1998]), formes ([Olivier 2003])ou d'écriture([Hallouli 2004a])

Défense : pour l'évaluation de comportement menaçants ([Johansson 2006],[Singh 2004],[Okello 2003])

Banque/Finance : pour l'analyse financière ou la détection de fraude

Marketing : dans le domaine du data mining pour l'analyse du comportement des consommateurs à partir de bases de données

Informatique : pour la sécurité des réseaux et d'internet

Environnement : pour la prédiction météorologique

A.1 Généralités sur les réseaux bayésiens

A.1.1 Introduction

Les réseaux bayésiens mêlent les outils de la théorie des graphes et de la théorie des probabilités. Ce formalisme très puissant permet ainsi une représentation intuitive (représentation qualitative) de la connaissance du système ainsi qu'une représentation quantitative grâce aux tables de probabilité. La représentation de la connaissance se base sur la construction d'un graphe acyclique \mathcal{G} dans lequel chaque nœud représente une variable du système et les arcs les relations de causalité existant entre elle. A chaque variable est associée une distribution de probabilité locale quantifiant la relation causale.

A.1.2 Définition

Définition A.1.1 (Réseau bayésien). *Soient :*

- un graphe acyclique orienté $\mathfrak{G} = (\mathcal{V}, \mathcal{A})$, où \mathcal{V} est l'ensemble des nœuds de \mathcal{G} et \mathcal{A} l'ensemble de ses arcs.

- un espace probabilisé fini (Ω, \mathcal{Z}, P) , contenant N variables aléatoires $(\forall N \in \mathbb{N}^+)$ $\{X_1, \dots, X_N\}$.

L'ensemble (\mathfrak{G}, P) est un réseau bayésien si et seulement si

- il existe une bijection entre les nœuds \mathcal{V} du graphe \mathfrak{G} et les variables du système $\{S_1, \dots, S_N\}$.

- la propriété suivante est vérifiée :

$$P\{X_1, \dots, X_N\} = \prod_{i=1}^N P\{X_i | Pa(X_i)\} \quad (\text{A.1})$$

où $Pa(X_i)$ représente les nœuds parents de X_i .

En effet, quel que soit le type de relation observée, la probabilité conditionnelle d'un nœud ne dépend que des nœuds parents (appelés parfois aussi *prédécesseur*). Ainsi, par exemple dans le cas de la liaison divergente (cf. Figure A.2), $P\{X_3 | X_1, X_2\} = P\{X_3 | X_2\}$. Cette relation est la clé de voute des réseaux bayésiens, puisque c'est à travers elle que s'expriment les relations de causalité entre les variables, limitant ainsi le nombre de probabilités conditionnelles à calculer.

A.1.3 Structure

Il existe trois relations pouvant lier des évènements dans un réseau bayésien :

- liaison linéaire (cf. Figure A.1)
- liaison divergente (cf. Figure A.2)
- liaison convergente (cf. Figure A.3)




Fig. A.1 – Linéaire




Fig. A.2 – Divergente





Fig. A.3 – Convergente

Prenons le réseau bayésien présenté dans la figure A.4 (exemple extrait de [Bellot 2002]) qui modélise la probabilité pour un chemin d’être glissant ou non à travers l’étude de 4 variables supplémentaires : la saison X_1 , si l’arrosage est en marche X_2 , si la pluie tombe X_3 et si le chemin est mouillé X_4 . Il est graphiquement visible qu’aucun lien n’existe entre la variable X_1 et X_5 . Cela confirme notre compréhension intuitive du problème, à savoir que la saison n’a pas une influence directe sur le fait que le chemin soit mouillé ou non. Il n’y a donc pas d’intérêt à calculer la probabilité conditionnelle de X_1 avec X_5 . L’évaluation globale du graphe va donc se faire de la façon suivante :

$$P\{X_1, \dots, X_5\} = P\{X_1\} \times P\{X_2|X_1\} \times P\{X_3|X_1\} \times P\{X_4|X_2, X_3\} \times P\{X_5|X_4\} \quad (\text{A.2})$$



X_1 : Saison {Printemps, t, Automne, Hiver} X_2 : Arrosage {on, off} X_3 : Pluie {oui, non} X_4 : Chemin mouillé {oui, non} X_5 : Chemin glissant {oui, non}
--

Fig. A.4 – Un exemple de réseau bayésien avec 5 variables

A.1.4 La d-séparation : définition et propriété

Pour savoir si il existe un *blocage* de l’information entre deux variable ou deux groupes de variables, la notion de *d-séparation* est utilisée et il s’agit d’une notion très importante puisqu’elle permet de déterminer si l’entrée d’une certitude (instanciation) dans une partie du réseau influence les probabilités d’une autre partie du réseau. Elle précise dans quelles conditions une information peut être traitée localement sans perturber l’ensemble du graphe. Le principe de la **d-séparation** est de déterminer si deux variables quelconques sont indépendantes conditionnellement à un ensemble de variables instanciées.

Définition A.1.2 (d-séparation). *Un chemin orienté entre deux nœuds représentant les variables X_i et X_j est bloqué par un ensemble de nœuds E si au moins une des deux conditions suivantes est vérifiée :*

- le chemin¹ orienté converge en un nœud $X_k \notin E$ tel que l'ensemble des nœuds parents de X_k noté $\mathcal{ND}(X_k)$ vérifie $\mathcal{ND}(X_k) \cap E = \emptyset$
- le chemin passe par un nœud $X_k \in E$ et la connexion en X_k est soit divergente, soit en série.

Un ensemble E d-sépare les ensembles X et Y si tout chemin entre un élément de X et un élément de Y est bloqué par E .

L'implication probabiliste de la notion de d-séparation est que si X et Y sont d-séparés par E (notation : $(X \parallel Y|E)_G$) dans un réseau bayésien, alors X et Y sont indépendants conditionnellement à E (notation : $(X \parallel Y|E)_P$).

Prenons comme exemple les différentes structures de liaisons. Concernant la liaison convergente (cf. Figure A.1), il n'y a pas de d-séparation de X_1 et X_3 par X_2 , tandis que pour les liaisons divergentes et série (cf. Figure A.2, A.3), $X_1 \parallel X_3|X_2$.

A.1.5 Construction d'un réseau bayésien et apprentissage

La construction d'un réseau bayésien se fait en trois étapes :

1. Définition des variables d'état : Quel que soit le système voulu, nous voulons faire son évaluation de la manière la plus précise possible. Il faut donc dans un premier temps évaluer toutes les variables pertinentes par rapport à la problématique étudiée.
2. Etude qualitative : définir les relations d'influence qui existent entre les variables
3. Etude quantitative : spécifier numériquement les distributions de probabilités conditionnelles

Si intuitivement ces étapes paraissent claires, pratiquement il ne paraît pas si évident de mettre en œuvre les étapes 2 et 3, et plus particulièrement l'étape 3 puisqu'elle fait intervenir des données numériques. Une solution existe : l'apprentissage soit par expertise, soit à partir d'un jeu de données. L'apprentissage par expertise pose le délicat problème de l'intervention humaine. Si elle est largement envisageable au niveau de l'étape 2, elle semble plus délicate pour l'étape 3 où doivent être transposées des données en probabilité. L'apprentissage à partir d'un jeu de données, bien que complexe, constitue donc une alternative fiable, si on dispose d'un jeu de données.

A.1.5.1 Apprentissage de structure

L'apprentissage de la structure d'un réseau bayésien n'est pas une tâche aisée. Le nombre de structures possibles pour un réseau contenant n nœuds est super-exponentiel. Il n'est donc pas envisageable de faire un parcours exhaustif des structures et de choisir le meilleur au delà de 7 ou 8 nœuds. Les algorithmes d'apprentissage de structure utilisent donc des heuristiques de recherche dans l'espace des graphes acycliques dirigés auquel appartient un réseau bayésien. Pour que la recherche soit efficace, le graphe se construit progressivement grâce à des ajouts et des suppressions d'arc et en utilisant une fonction score calculable localement pour limiter le calcul à la variation locale qui existe entre deux structures. Le score $S(\mathcal{G})$ d'un réseau \mathcal{G} doit être d'une des deux formes suivantes :

$$S(\mathcal{G}) = \sum_{i=1}^n s(X_i, pa(X_i)) \quad \text{ou} \quad S(\mathcal{G}) = \prod_{i=1}^n s(X_i, pa(X_i)) \quad (\text{A.3})$$

¹un chemin est une séquence consécutive d'arcs non dirigés dans le graphe

Il existe ensuite un nombre important d'algorithmes différents pour les heuristiques de recherche. Les plus connus sont l'algorithme PC, l'algorithme de poids minimum, l'algorithme K2, la recherche gloutonne ou encore le Structural-EM, variation de l'algorithme d'Expectation-Maximisation. Pour une description plus complète de ces algorithmes, nous recommandons la lecture de [Olivier 1988] et de [Auvray 2001]

A.1.5.2 Apprentissage des probabilités conditionnelles initiales

A partir d'une base de données existante, l'ensemble des probabilités sont initialisées. Cette étape pour un nœud dépend de la nature de la variable représentée (discrète ou continue) et de la nature de ses parents. Cette étape d'initialisation est cruciale pour l'efficacité du processus d'inférence qui va suivre. A noter que si un nœud fils est discret et que ses parents sont continus, il n'existe pas de méthodes d'initialisation exacte.

A.2 Inférence bayésienne

Un réseau bayésien permet donc de représenter un ensemble X de variables aléatoires tel que $\forall N \in \mathbb{N}^+$, l'ensemble $X = \{X_1, \dots, X_N\}$ ainsi que les relations de dépendances existant entre ces variables. $P(X)$ désigne la distribution de probabilité sur cet ensemble. Si nous disposons d'une nouvelle information ε sur notre système, alors il est souhaitable de mettre à jour la connaissance que nous avons du système à travers le réseau bayésien. Cette mise à jour se fait en utilisant la règle de Bayes pour le calcul de la distribution de probabilités *a posteriori* $P(X|\varepsilon)$.

Cependant, il faut trouver un moyen de propager cette information dans un réseau parfois compliqué. Plusieurs méthodes ont dès lors été proposées. Il existe plusieurs méthodes d'inférence exacte, celles-ci sont assez finement décrites dans [Meviren 2004]. Une méthode d'inférence exacte reprise dans bon nombre d'applications (*cf.* [Hallouli 2004a],[Djebbar 2006]) est celle du JLO du nom de ses auteurs Jensen, Lauritzen et Olesen qui a pour principe de transformer le graphe \mathcal{G} représentant le réseau bayésien en un arbre de jonction \mathcal{T} , ensemble équivalent à \mathcal{G} de sous-graphes complets (cliques) les plus petits possibles dans lesquels l'information est plus facile à propager. Une autre solution, d'approximation cette fois, très usitée dans le cas où les données sont incomplètes ou lorsque le réseau est très complexe est l'algorithme EM (Expectation Maximisation).

A.2.1 L'algorithme JLO

L'algorithme se déroule en deux étapes : une première étape de prétraitement pour obtenir un arbre de jonction et une étape de propagation où les nouvelles informations sont propagées grâce à l'arbre de jonction.

A.2.1.1 Construction de l'arbre de jonction

La transformation du réseau bayésien (*cf.* Figure A.5 - (a)) en arbre de jonction se fait en trois étapes :

- La moralisation (*cf.* Figure A.5 - (b)) : tous les arcs dirigés sont transformés en arcs non-dirigés puis tous les parents d'une même variable sont mariés deux à deux.

- La triangulation (*cf.* Figure A.5 - (c)) : le graphe moralisé précédemment décrit est triangulé afin d'en extraire des cliques de noeuds qui sont des sous graphes complets² du réseau bayésien. Un graphe est dit « triangulé » si et seulement si tous ses noeuds peuvent être éliminés. Un noeud peut être éliminé lorsque tous ses voisins sont connectés deux à deux c'est à dire si il appartient à une clique dans le graphe. Si un noeud n'est pas éliminable, il est possible de rajouter des arcs. Pour des raisons de complexités calculatoires, il est souhaitable d'obtenir des cliques les plus petites possibles, en effet ces cliques forment par la suite les noeuds de l'arbre de jonction. Cependant, la triangulation est un problème NP-complet, plusieurs approches ont été retenues par la communauté scientifique comme l'algorithme de triangulation avec critère d'optimalité ou par ajout du minimum d'arc.

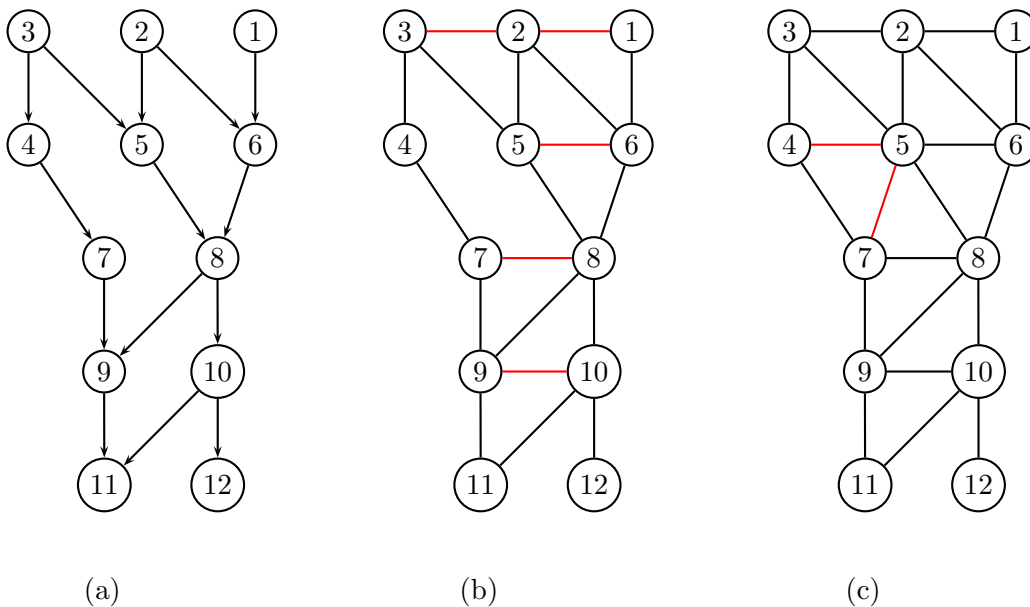


Fig. A.5 – Transformation du réseau bayésien - (a) réseau bayésien - (b) Moralisation - (c) Triangulation

- Formation de l'arbre de jonction : dans le processus d'inférence, l'arbre de jonction est calculé une fois et une seule, cependant selon l'algorithme de triangulation choisi, plusieurs arbres de jonction sont envisageables.

Définition A.2.1 (Arbre de jonction). Soit $\mathcal{C} = \{C_1, \dots, C_M\}$ un ensemble de sous-ensemble d'un ensemble fini de nœuds \mathcal{V} et soit \mathcal{T} un arbre dont l'ensemble de nœuds est \mathcal{C} . L'arbre \mathcal{T} est appelé arbre de jonction si et seulement si $\forall (i, j) \in \{1, \dots, M\}$ tel que $i \neq j$, pour toutes les paires (C_i, C_j) issue de \mathcal{C} , l'intersection $S_{ij} = C_i \cap C_j$ est contenue dans chaque nœud sur le chemin unique allant de C_i à C_j dans \mathcal{T} et est non vide. L'ensemble S_{ij} est appelé séparateur (*sepset*). De plus, l'ensemble des séparateurs est désigné par \mathcal{S} .

Dans notre application, désignons par C_1 et C_2 les deux premiers nœuds de l'arbre tel que $C_1 = \{1; 2; 6\}$ et $C_2 = \{2; 5; 6\}$ où $\{1; 2; 5; 6\}$ fait partie de l'ensemble $\mathcal{V} = \{1, \dots, 12\}$ des nœuds. Nous voyons que l'intersection $C_1 \cap C_2 = \{2; 6\}$ est non nulle et est contenue dans C_1 et C_2 .

²C'est le graphe dont les sommets sont tous reliés deux à deux par une arête

Après cette première étape de construction, nous pouvons à présent aborder les problèmes d'initialisation des tables de probabilité.

A.2.1.2 Initialisation de l'arbre de jonction

Il s'agit d'évaluer les probabilités liées à l'arbre \mathcal{T} de jonction de façon équivalente au graphe \mathcal{G} initial, dont nous sommes sensés connaître les distributions de probabilités conditionnelles de l'ensemble des variables $\mathcal{S} = \{X_1, \dots, X_N\} : P(X_i | \text{Parent}(X_i))$. Cela se fait en trois étapes :

1. Assigner chaque S_i à une clique $C_j \forall i \in \{1, \dots, N\}$ et $\forall j \in \{1, \dots, M\}$
2. Pour chaque clique à qui est assignée au moins une variable, calculer la fonction potentielle a_C de la clique comme le produit des $P\{X_i | Pa(X_i)\}$ de toutes les variables affectées à cette clique.

$$\forall i \in \{1, \dots, M\}, a_C(C_i) = \prod_{X \in C_i} P\{X | \text{Parent}(X)\} \quad (\text{A.4})$$

3. Pour chaque séparateur, assigner la valeur 1 au potentiel $b_S(S)$.

Finalement, l'expression de la distribution de probabilité jointe du réseau bayésien peut s'écrire de la façon suivante :

$$P\{S_1, \dots, S_N\} = \frac{\prod_{C \in \mathcal{C}} P\{X_C\}}{\prod_{S \in \mathcal{S}} P\{X_S\}} \quad (\text{A.5})$$

A.2.1.3 Propagation de l'information

Le principe avec le JLO est de transmettre l'information de cliques en cliques. Pour cela, la notion de *flux* d'une clique C_i à une clique $C_j (\forall (i, j) \in \{1, \dots, M\})$ est introduite. Or ce flux entre deux cliques est définie grâce au séparateur S_{ij} . Tout d'abord le flux initial $\Phi_{S_{ij}}$ est mis à jour par marginalisation du potentiel des cliques à travers les variables qui sont dans C_i mais pas dans S_{ij} :

$$\Phi_{S_{ij}}^* = \sum_{C_i/S_{ij}} a_C(X_{C_i}) \quad (\text{A.6})$$

Le facteur de mise à jour du flux peut s'écrire comme le ratio entre le flux mis à jour et l'ancien flux :

$$\lambda_{S_{ij}} = \frac{\Phi_{S_{ij}}^*}{\Phi_{S_{ij}}} \quad (\text{A.7})$$

La probabilité associée à la clique C_i peut à présent être mise à jour :

$$a_C^*(C_i) = a_C(C_i) \times \lambda_{S_{ij}} \quad (\text{A.8})$$

A.2.2 L'algorithme EM

L'algorithme EM, pour Expectation-Maximisation ou Espérance-Maximisation en français, permet de traiter des bases de données incomplètes sans avoir à ajouter une nouvelle modalité signifiant qu'une donnée n'est pas mesurée à chaque nœud. A partir des données initiales, l'espérance des données manquantes va être estimée de façon itérative jusqu'à convergence de ces estimations. En d'autres termes, cet algorithme maximise, de façon

itérative dans l'espace des variables du système, la fonction de vraisemblance des observations Y , c'est à dire la densité de probabilité $P(Y|X)$ de l'ensemble des observations conditionnées sur l'ensemble des variables du système X .

A.3 Les réseaux bayésiens dynamiques

Les réseaux bayésiens dynamiques ou **DBN** pour Dynamic Bayesian Networks en anglais étendent la représentation des réseaux bayésiens aux processus dynamiques. Il s'agit en fait d'une chaîne du même réseau bayésien répété autant de fois que nécessaire (suivant la longueur de la séquence d'observations). Chaque répétition est un pas de temps permettant de représenter l'évolution du phénomène stochastique. Ils contiennent chacun un certain nombre de variables aléatoires représentant les observations et les états cachés du processus. La figure A.6 présente l'exemple précédent A.4 présenté de manière dynamique, où nous considérons que la connaissance que nous avons sur la pluie à l'itération $k - 1$ a une influence sur la probabilité qu'il ait plu à l'itération k et que de plus l'état X_2 (grisé) est un état caché.




Fig. A.6 – Un exemple de réseau bayésien dynamique

Soit $X(t)$ l'ensemble des variables du système à un temps t tel que $(\forall N \in \mathbb{N}^+) X(t) = \{X_1(t), \dots, X_N(t)\}$. De la même façon que pour un réseau bayésien classique (*cf.* équation (A.1)), la densité jointe de probabilité d'un réseau bayésien pour un intervalle de temps fini $[1, T]$ s'écrit :

$$P(X(1), \dots, X(T)) = \prod_{t=1}^T \prod_{i=1}^N P(X_i(t) | Pa(X_i(t))) \quad (\text{A.9})$$

A.4 Les modèles de Markov cachés

A.4.1 Les chaînes de Markov du 1 ordre

Les Modèles de Markov cachés ou HMM pour Hidden Markov Models servent à modéliser l'évolution dans le temps d'un processus stochastique. Nous considérons un système donné qui est dans un état n parmi N états distincts notés x_1, \dots, x_N . A intervalle de temps régulier, le système évolue et change d'état ou non. A l'instant t , nous notons $X(t)$ l'état du système. Le passage d'un état x_i à x_j se fait avec une certaine probabilité notée :

$$\forall(i, j, k) \in \{1, \dots, N\}, P(X(t) = X_j | X(t-1) = x_i, X(t-2) = x_k, \dots) \quad (\text{A.10})$$

qui dépend des états antérieurs du système.

Dans les modèles de Markov du premier ordre, nous considérons que l'état du système à l'itération t ne dépend que de l'état du système à l'itération $t-1$. La probabilité que l'état du système soit X_i à l'itération t sachant qu'il était dans l'état X_j à l'itération $t-1$ est égale s'écrit alors :

$$\forall(i, j) \in \{1, \dots, N\}, P(X(t) = X_j | X(t-1) = x_i, X(t-2) = x_k, \dots) = P(X(t) = x_j | X(t-1) = x_i) \quad (\text{A.11})$$

Sous cette condition et en considérant que le modèle de Markov est homogène, nous pouvons construire une matrice A des probabilités de transitions indépendante du temps telle que

$$A = (a_{ij})_{1 \leq i, j \leq N} \quad (\text{A.12})$$

telle que :

$$a_{ij} = P(X(t) = x_j | X(t-1) = x_i) \quad (\text{A.13})$$

La matrice A est stochastique³, ce qui peut s'écrire :

$$\begin{cases} a_{ij} \leq 0, \forall(i, j) \in \{1, \dots, N\} \\ \sum_{j=1}^N a_{ij} = 1 \end{cases} \quad (\text{A.14})$$

A.4.2 Les modèles de Markov cachés

Dans le cas précédent, nous étions dans le cadre de modèles de Markov dit *observables*, c'est à dire que l'état du système correspond à un seul type d'observation. Nous nous plaçons à présent dans un cadre plus complexe, lorsque nous ne disposons plus que d'une probabilité de correspondance d'une observation à un état. On parle dans ce cas d'états cachés.

Soit M , le nombre d'observations qu'il est possible de faire et $Y = \{y_1, \dots, y_M\}$ l'ensemble discrets des M observations. Nous définissons par B , la matrice des probabilités d'observations telle que :

$$B = (a_{ij})_{1 \leq i \leq N, 1 \leq j \leq M} \quad (\text{A.15})$$

telle que :

$$b_{ij} = P(z(t) = y_j | X(t) = X_i) \quad (\text{A.16})$$

³La somme des éléments de chaque ligne est égale à 1

où $z(t)$ est l'observation faite à l'itération t , b_{ij} est donc la probabilité de faire l'observation j en étant dans l'état x_i . La matrice est donc également stochastique et s'écrit donc sous la forme suivante :

$$\begin{cases} b_{ij} \leq 0, \forall i \in \{1, \dots, N\}, \forall j \in \{1, \dots, M\} \\ \sum_{j=1}^M b_{ij} = 1 \end{cases} \quad (\text{A.17})$$

La figure A.7 illustre ce concept. Les états sont $\{x_1, x_2, x_3\}$ et les observations possibles $\{y_1, y_2, y_3, y_4\}$




Fig. A.7 – Illustration des notations du HMM

Nous désignons par $Z = \{z_1, \dots, z_T\}$ une séquence d'observation de longueur T . Les observations sont supposées indépendantes, ce qui se traduit finalement par la relation suivante :

$$P(Z|X) = P(z_1, \dots, z_T | x_1, \dots, x_M) = \prod_{t=1}^T P(z_t | x_t) \quad (\text{A.18})$$

Finalement, un modèle de Markov caché peut s'écrire :

$$\Lambda = (A, B, \Pi) \quad (\text{A.19})$$

où Π désigne les densités de probabilités initiales de chaque état.

$$\Lambda = (A, B, \Pi) \quad (\text{A.20})$$

A.4.3 Applications possibles pour les HMM

Pour qu'il soit utile d'utiliser les HMM, le problème à résoudre doit être de la nature suivante :

A.4.3.1 Estimation de la probabilité d'observation

Étant donnée une séquence d'observation Z et un HMM Λ , quelle est la probabilité de générer Z par le modèle Λ , autrement dit, quelle est la fiabilité du modèle associé aux observations. Or la probabilité des observations est égale à la somme des probabilités que les observations soient associées à tous les chemins possibles, soit :

$$P(Z|\Lambda) = \sum_X P(Z|X, \Lambda)P(X|\Lambda) \quad (\text{A.21})$$

Le calcul de tous les chemins possibles étant une opération très coûteuse en temps, il est préférable d'utiliser un algorithme de *forward-backward* pour réaliser cette opération.

A.4.3.2 Apprentissage du modèle

En disposant de n séquences de mesures indépendantes, il est possible de trouver le modèle Λ qui maximise $P(Z|\Lambda)$. Le but de l'apprentissage est donc de trouver les paramètres (A, B, Π) qui maximise le produit :

$$\prod_{k=1}^n P(Z^k|\Lambda) \quad (\text{A.22})$$

Il s'agit d'un problème d'optimisation. La solution la plus couramment utilisée est celle de *Baum-Welch*. Il s'agit pour la vraisemblance d'atteindre son maximum local par estimations itératives des paramètres (A, B, Π) .

A.4.3.3 Reconnaissance d'une séquence d'état

Étant donné une séquence d'observation Z et un modèle Λ , il s'agit de déterminer la séquence d'état Q cachés qui a la plus forte vraisemblance avec les observations. Cette application est très souvent utilisée pour les problèmes de classification vidéo. Il s'agit donc d'estimer \hat{Q} :

$$\hat{Q} = \underset{Q}{\operatorname{argmax}} P(Z|Q, \Lambda)P(Q|\Lambda) \quad (\text{A.23})$$

Cette estimation se fait grâce à l'algorithme de *Viterbi*.

Bibliographie

- [Adeli 2001] H. Adeli. *Neural networks in civil engineering : 1989-2000*. Computer-Aided Civil and Infrastructure Engineering, vol. 16, no. 2, pages 126–142, 2001. 63
- [Ameur 2007] Z. Ameur, M. Lazri et S. Ameur. *Identification des masses nuageuses par fusion de données images (radar-satellite)*. Larhyss Journal, vol. 6, pages 105–120, 2007. 9
- [A.N. Steinberg 1998] F.E. White A.N. Steinberg C.L. Bowman. *Revision of the JDL Model*. Proceedings of the SPIE, vol. 3719, pages 330–441, 1998. 10
- [A.N. Steinberg 2004] C.L. Bowman A.N. Steinberg. *Rethinking the JDL Data Fusion Levels*. Proceedings of the National Symposium on Sensor and Data Fusion, 2004. 2, 10
- [Auvray 2001] Vincent Auvray. *Apprentissage automatique des réseaux bayesiens*. Master's thesis, Université de, 2001. 245
- [Bar-Shalom 1988] Y. Bar-Shalom et T.E. Fortmann. *Tracking and data association*. Academic Press, 1988. 48
- [Bar-Shalom 1993] Y. Bar-Shalom et X.R. Li. *Estimation and tracking : Principle, techniques and software*. Artech House, 1993. 39, 56
- [Bar-Shalom 1995] Y. Bar-Shalom. *Multitarget-multisensor tracking : Principle and techniques*. Academic Press, 1995. 54
- [Bar-Shalom 2000] Y. Bar-Shalom et D.B. Blair. *Multitarget-multisensr tracking : applications and advances volume iii*. Artech House, 2000. 36
- [Barillot 1994] C. Barillot, D. Lemoine, L. le Briquer, F. Lachmann et B. Gibaud. *Data Fusion in Medical Imaging : Merging Multimodal and Multipatient Images, Identification of Structures and 3D Display Aspects*. In Bemmell J. H. Van et McCray A.T, éditeurs, *Advanced Communications in Health Care, IMIA Yearbook of Medical Informatics*, pages 290–295. Schattauer Publisher, 1994. 9
- [Bedworth 2000] M. Bedworth, J. O'Brien et M. Jemity. *The Omnibus model : a new model of data fusion ?* IEEE Aerospace and Electronic Systems Magazine, vol. 15, no. 4, pages 30–36, 2000. 9
- [Bellot 2002] David Bellot. *Fusion de données avec des réseaux bayesiens pour la modélisation des systèmes dynamiques et son application en télé-médecine*. PhD thesis, Université Poincarre Nancy, 2002. 9, 117, 241, 243
- [Benavoli 2007] A. Benavoli, B. Ristic, A. Farina, M. Oxenham et L. Chisci. *An approach to threat assessment based on evidential networks*. 10th International Conference on Information Fusion, pages 1–8, July 2007. 126, 138
- [Blackman 1986] S Blackman. *Multiple target tracking with radar applications*. Artech House, 1986. 52, 53, 54
- [Blackman 1999] S. Blackman et R. Popoli. *Design and analysis of modern tracking systems*. Artech House, 1999. 53, 75

- [Bloch 1996] I. Bloch. *Information combination operators for data fusion : a comparative review with classification*. IEEE Transactions on Systems, Man and Cybernetics, Part A, vol. 26, no. 1, pages 52–67, 1996. 20
- [Bloch 2003] I. Bloch. Fusion d'informations en traitement du signal et des images. Hermes Science Publication, 2003. 2
- [Blom 1988] HAP Blom et Y. Bar-Shalom. *The interacting multiple model algorithm for systems with Markovian switching coefficients*. IEEE Transactions on Automatic Control, vol. 33, no. 8, pages 780–783, 1988. 56
- [Boulard 2003] H. Boulard. *Reconnaissance de la parole et du locuteur*. Rapport technique, Ecole Polytechnique Fédérale de Lausanne, 2003. 63
- [Choppy 2009] C. Choppy, O. Bertrand et P. Carle. *Coloured Petri Nets for Chronicle Recognition*. Reliable Software Technologies–Ada-Europe, pages 266–281, 2009. 64
- [Clark 2006a] Daniel Clark, Ba-Ngu Vo et Judith Bell. *GM-PHD Filter Multitarget Tracking in sonar images*. volume 1, page 6235. SPIE, 2006. 43
- [Clark 2006b] D.E. Clark, K. Panta et B.-N. Vo. *The GM-PHD Filter Multiple Target Tracker*. pages 1–8, July 2006. 82
- [Clark 2007] D.E. Clark et J. Bell. *Multi-target state estimation and track continuity for the particle PHD filter*. IEEE Transactions on Aerospace and Electronic Systems, vol. 43, no. 4, pages 1441–1453, October 2007. 43, 83
- [Corbeil 2006] A. Corbeil, G. Van Patten, L. Spoldi, B. O'Hern et M. Alford. *Data mining of GMTI radar databases*. IEEE Conference on Radar, pages 8 pp.–, April 2006. 2
- [Cox 1946] R.T. Cox. *Probability, frequency and reasonable expectation*. American journal of physics, vol. 14, no. 1, pages 1–13, 1946. 20
- [Das 2002] S. Das, R. Grey et P. Gonsalves. *Situation assessment via Bayesian belief networks*. In Proceedings of the 5th International Conference on Information Fusion, 2002. 138
- [Deb 1997] Somnath Deb, Murali Yeddanapudi, Krishna Pattipati et Y. Bar-Shalom. *A generalized S-D assignment algorithm for multisensor-multitarget state estimation*. IEEE Transactions on Aerospace and Electronic Systems, vol. 33, no. 2, pages 523–538, April 1997. 58
- [Demos 1990] G.C. Demos, R.A. Ribas, T.J. Broida et S.S. Blackman. *Applications of MHT to dim moving targets*. In Proc. SPIE, volume 1305, pages 297–309, 1990. 52
- [Dempster 2008] A. Dempster. *Upper and lower probabilities induced by a multivalued mapping*. Classic Works of the Dempster-Shafer Theory of Belief Functions, pages 57–72, 2008. 24
- [Desodt-Lebrun 1996] A.M. Desodt-Lebrun. *Fusion de données*. Techniques de l'ingénieur. Informatique industrielle, vol. 12, no. R7226, pages 1–9, 1996. 20
- [Dezert] Jean Dezert. *Introduction au pistage multi-cibles multi-senseurs*. Rapport technique, Cours ENSTA. 49, 55, 56
- [Dezert 2006] J. Dezert, A. Tchamova, F. Smarandache et P. Konstantinova. *Target Type Tracking with PCR5 and Dempster's rules : A Comparative Analysis*. Arxiv preprint cs/0607143, 2006. 104

- [Dickmanns 2007] E.D. Dickmanns. *Dynamic vision for perception and control of motion*. Springer Verlag, 2007. 8
- [Djebbar 2006] A. Djebbar et H.F. Merouani. *Vers une modélisation de la base de cas par un réseau bayésien : application d'aide au diagnostic des pathologies hiéatiques*. MOSIM'06, 2006. 61, 241, 245
- [Donat 2009] Roland Donat. *Modélisation de la Fiabilité et de la Maintenance par Modèles Graphiques Probabilistes - Application à la Prévention des Ruptures de Rails*. PhD thesis, l'Institut National des Sciences Appliquées de Rouen, 2009. 117
- [Doré 2009] Pierre-Emmanuel Doré, Arnaud Martin et Ali Khenchaf. *Constructing of a Consonant Belief Function Induced by a Multimodal Probability Density*. In COGIS, 2009. 32
- [Doucet 2000] Arnaud Doucet, Simon Godsill et Christophe Andrieu. *On sequential Monte Carlo sampling methods for Bayesian filtering*. *Statistics and Computing*, vol. 10, no. 3, pages 197–208, 2000. 46, 47
- [Dousson 1994] Christophe Dousson. *Suivi d'évolutions et reconnaissance de chroniques*. PhD thesis, Ecole nationale supérieure de l'aéronautique et de l'aérospatiale, 1994. 64
- [Dubois 1988] D. Dubois et H. Prade. *Possibility theory : an approach to computerized processing of uncertainty*. 1988. 22
- [Dubois 1991] Didier Dubois et Henri Prade. *Fuzzy sets in approximate reasoning, Part 1 : Inference with possibility distributions*. *Fuzzy Sets and Systems*, vol. 40, no. 1, pages 143 – 202, 1991. 23
- [Ehlers 1991] Manfred Ehlers. *Multisensor image fusion techniques in remote sensing*. *ISPRS Journal of Photogrammetry and Remote Sensing*, vol. 46, no. 1, pages 19 – 30, 1991. 9
- [El Najjar 2005] M.E. El Najjar et P. Bonnifait. *A road-matching method for precise vehicle localization using belief theory and Kalman filtering*. *Autonomous Robots*, vol. 19, no. 2, pages 173–191, 2005. 99
- [Erdinc 2005] O. Erdinc, P. Willett et Y. Bar-Shalom. *Probability hypothesis density filter for multitarget multisensor tracking*. 8th International Conference on Information Fusion, vol. 1, pages 8 pp.–, July 2005. 41, 72
- [Erdinc 2009] O. Erdinc, P. Willett et Y. Bar-Shalom. *The Bin-Occupancy Filter and Its Connection to the PHD Filters*. *IEEE Transactions on Signal Processing*, vol. 57, no. 11, pages 4232 –4246, nov. 2009. 72
- [Eude 1998] Virginie Eude. *Modélisation spatio-temporelle floue pour la reconnaissance d'activités militaires*. PhD thesis, Université Paris 6, 1998. 60
- [Franken 2009] D. Franken, M. Schmidt et M. Ulmke. *"Spooky Action at a Distance" in the Cardinalized Probability Hypothesis Density Filter*. *IEEE Transactions on Aerospace and Electronic Systems*, vol. 45, no. 4, pages 1657 –1664, oct. 2009. 72
- [Gebhardt 1996] J. Gebhardt et R. Kruse. *Learning possibilistic networks from data*. *Learning from data : artificial intelligence and statistics V*, page 143, 1996. 117
- [Goodman 1997] I.R. Goodman, R. Mahler et Nguyen H.T. *Mathematics of Data Fusion*. Kluwer academic publishers, 1997. 80

- [Gordon 1993] N.J. Gordon, D.J. Salmond et A.F.M. Smith. *Novel approach to nonlinear/non-Gaussian Bayesian state estimation*. In IEEE Proceedings, volume 140, pages 107–113, 1993. 44
- [Gordon 1996] Neil J. Gordon et David J. Salmond. *Bayesian target selection after group pattern distortion*. volume 2759, pages 279–292. SPIE, 1996. 44, 71
- [Gordon 1997] Neil Gordon. *A Hybrid Bootstrap Filter for Target Tracking in Clutter*. IEEE Transactions on Aerospace and Electronic Systems, vol. 33, pages 353–358, 1997. 48
- [Grandin 2006] J.F. Grandin. *Fusion de données : Théorie et méthodes*. Techniques de l'ingénieur. Informatique industrielle, vol. 2, no. S7224, 2006. 20
- [Hall 1997] D.L. Hall et J. Llinas. *An introduction to multisensor data fusion*. Proceedings of the IEEE, vol. 85, no. 1, pages 6–23, Jan 1997. 9
- [Hall 2001] D.L. Hall et J. Llinas. Handbook of Multisensor Data Fusion. CRC, 2001. 9
- [Hallouli 2004a] K. Hallouli, L. Kifkorman-Sulem et M. Sigelle. *Reconnaissance de caractères manuscrits par Réseaux Bayésiens Dynamiques*. 2004. 241, 245
- [Hallouli 2004b] Khalid Hallouli. *Reconnaissance de caractères par méthodes markoviennes et réseaux bayésiens*. PhD thesis, ENST, 2004. 117
- [Heckerman 1995] D. Heckerman. *A tutorial on learning with bayesian networks*, 1995. 61
- [Henzinger 2004] Monika R. Henzinger. *Algorithmic Challenges in Web Search Engines*. Internet Mathematics, 2004. 60
- [Hoffman 2002] J.R. Hoffman et R.P.S. Mahler. *Multitarget miss distance and its applications*. In Proceedings of the Fifth International Conference on Information Fusion, volume 1, pages 149–155 vol.1, 2002. 158
- [Hoffman 2004] J.R. Hoffman et R.P.S. Mahler. *Multitarget Miss Distance via Optimal Assignment*. IEEE Transactions on Systems, 2004. 158
- [Hongeng 2004] Somboon Hongeng, Ram Nevatia et Francois Bremond. *Video-based event recognition : activity representation and probabilistic recognition methods*. Computer Vision and Image Understanding, vol. 96, no. 2, pages 129 – 162, 2004. Special Issue on Event Detection in Video. 58
- [Hue 2000] C. Hue, J.P. Le Cadre et P. Perez. *Tracking multiple objects with particle filtering*. Rapport technique, INRIA, 2000. 49
- [Isard 1998] Michael Isard et Andrew Blake. *CONDENSATION - conditional density propagation for visual tracking*. International Journal of Computer Vision, vol. 29, pages 5–28, 1998. 48
- [Jazwinski 1970] A.H. Jazwinski. Stochastic processes and filtering theory. Academic Pr, 1970. 44
- [Jensen 1990] F. V. Jensen, S. L. Lauritzen et K. G. Olesen. *Bayesian updating in recursive graphical models by local computation*. Computational Statistics Quarterly, vol. 4, pages 269–282, 1990. 141, 240
- [Jensen 1996] K. Jensen. Coloured Petri nets : basic concepts, analysis methods, and practical use. Springer Verlag, 1996. 64
- [Johansson 2006] F. Johansson et G. Falkman. *Implementation and integration of a Bayesian Network for prediction of tactical intention into a ground target simulator*. 9th International Conference on Information Fusion, pages 1–7, July 2006. 138, 241

- [Julier 1997] S.J. Julier et J.K. Uhlmann. *A new extension of the Kalman filter to non-linear systems*. In Int. Symp. Aerospace/Defense Sensing, Simul. and Controls, volume 3, page 26. Citeseer, 1997. 44
- [Kalman 1960] R.E. Kalman. *A new approach to linear filtering and prediction problems*. Journal of basic Engineering, vol. 82, no. 1, pages 35–45, 1960. 39
- [Kanungo 2002] T. Kanungo, D.M. Mount, N.S. Netanyahu, C.D. Piatko, R. Silverman et A.Y. Wu. *An efficient k-means clustering algorithm : Analysis and implementation*. IEEE Transactions on Pattern Analysis and Machine Intelligence, vol. 24, no. 7, pages 881–892, 2002. 47
- [Karlsson 2001] R. Karlsson et F. Gustafsson. *Monte Carlo data association for multiple target tracking*. Target Tracking : Algorithms and Applications (Ref. No. 2001/174), IEE, vol. 1, page 13, 2001. 48
- [Kastella 1997] Keith D. Kastella. *Joint multitarget probabilities for detection and tracking*. volume 3086, pages 122–128. SPIE, 1997. 47
- [Kauffman 1984] Stuart A. Kauffman. *Emergent properties in random complex automata*. Physica D : Nonlinear Phenomena, vol. 10, no. 1-2, pages 145 – 156, 1984. 59
- [Kirubarajan 2000a] T. Kirubarajan, Y. Bar-Shalom, K.R. Pattipati et I. Kadar. *Ground target tracking with variable structure IMM estimator*. IEEE Transactions on Aerospace and Electronic Systems, vol. 36, no. 1, pages 26–46, Jan 2000. 75, 96, 99, 175
- [Kirubarajan 2000b] Thiagalingam Kirubarajan et Yaakov Bar-Shalom. *Tracking evasive move-stop-move targets with a MTI radar using a VS-IMM estimator*. volume 4048, pages 236–246. SPIE, 2000. 75
- [Kirubarajan 2004] T. Kirubarajan et Y. Bar-Shalom. *Probabilistic data association techniques for target tracking in clutter*. Proceedings of the IEEE, vol. 92, no. 3, pages 536–557, 2004. 54
- [Klemm 2008] R. Klemm et M. Mertens. *Tracking of convoys by airborne STAP radar*. 11th International Conference on Information Fusion, pages 1–8, 30 2008-July 3 2008. 2
- [Koch 2002] W. Koch. *Information fusion aspects related to GMTI convoy tracking*. ICIF, 2002. 2
- [Koller 2006] Jost Koller et Martin Ulmke. *Data Fusion for Ground Moving Target Tracking*. IEEE International Conference on Multisensor Fusion and Integration for Intelligent Systems, pages 217–224, Sept. 2006. 9
- [Kong 1994] A. Kong, J.S. Liu et W.H. Wong. *Sequential imputations and Bayesian missing data problems*. Journal of the American statistical association 93, 1994. 46
- [Kreucher 2003] Chris M. Kreucher, Keith D. Kastella et Alfred O. Hero III. *Tracking multiple targets using a particle filter representation of the joint multi-target probability density*. volume 5204, pages 258–269. SPIE, 2003. 47
- [Kreucher 2005] C. Kreucher, K. Kastella et III Hero A.O. *Multitarget tracking using the joint multitarget probability density*. IEEE Transactions on Aerospace and Electronic Systems, vol. 41, no. 4, pages 1396–1414, Oct. 2005. 47

- [Krogh 2001] A. Krogh, B.È. Larsson, G. Von Heijne et E.L.L. Sonnhammer. *Predicting transmembrane protein topology with a hidden markov model : application to complete genomes1*. Journal of molecular biology, vol. 305, no. 3, pages 567–580, 2001. 62
- [Kumar 2005] P. Kumar, S. Ranganath, Huang Weimin et K. Sengupta. *Framework for real-time behavior interpretation from traffic video*. IEEE Transactions on Intelligent Transportation Systems, vol. 6, no. 1, pages 43–53, March 2005. 61
- [Kurien 1990] T. Kurien. *Issues in the design of practical multitarget tracking algorithms*. Multitarget-Multisensor Tracking : Advanced Applications, pages 43–83, 1990. 52
- [Kyriakides 2000] I. Kyriakides, D. Morrell et A. Papandreou-Suppappola. *Multiple target tracking with constrained motion using particle filtering methods*. Statistic and computing, 2000. 48
- [Lan 2004] X. Lan et DP Huttenlocher. *A unified spatio-temporal articulated model for tracking*. In Proceedings of the 2004 IEEE Computer Society Conference on Computer Vision and Pattern Recognition, 2004. 63
- [Largouët 2000] Christine Largouët et Marie-Odile Cordier. *Timed Automata Model to Improve the Classification of a Sequence of Images*. In ECAI, pages 156–160, 2000. 60
- [Le Saux 2005] B. Le Saux et H. Bunke. *Feature selection for graph-based image classifiers*. In IAPR Iberian Conference on Pattern Recognition and Image Analysis, Estoril, Portugal, june 2005. 58
- [Leignel 2008] Christine Leignel et Jean-Michel Jolion. *Étude bibliographique suivi de personnes et trajectoire dans un réseau de caméras*. Rapport technique, Liris, 2008. 64
- [Lesire 2006] Charles Lesire. *Estimation numérico-symbolique pour le suivi d'activités hybrides*. PhD thesis, Ecole nationale supérieure de l'aéronautique et de l'espace, 2006. 64
- [Lin 2006] L. Lin, Y. Bar-Shalom et T. Kirubarajan. *Track and PHD filter for multitarget tracking*. IEEE Transactions on Aerospace and Electronic Systems, vol. 42, no. 3, pages 778–795, July 2006. 43, 83
- [Lloyd 1982] S. Lloyd. *Least squares quantization in PCM*. IEEE Transactions on Information Theory, vol. 28, no. 2, pages 129–137, 1982. 47
- [Lymberopoulos 2008] D. Lymberopoulos, T. Teixeira et A. Savvides. *Macroscopic Human Behavior Interpretation Using Distributed Imager and Other Sensors*. Proceedings of the IEEE, vol. 96, no. 10, pages 1657–1677, oct. 2008. 9
- [Maggio 2007] E. Maggio, E. Piccardo, C. Regazzoni et A. Cavallaro. *Particle PHD Filtering for multitarget Visual Tracking*. 10th International Conference on Information Fusion, 2007. 43
- [Mahler 2003] R.P.S. Mahler. *Multitarget Bayes filtering via first-order multitarget moments*. IEEE Transactions on Aerospace and Electronic Systems, vol. 39, no. 4, pages 1152–1178, Oct. 2003. 37, 40
- [Mahler 2006] Ronald Mahler. *A theory of PHD filters of higher order in target number*. volume 6235, page 62350K. SPIE, 2006. 37, 41, 42, 82

-
- [Mahler 2007a] R. Mahler. *PHD filters of higher order in target number*. IEEE Transactions on Aerospace and Electronic Systems, vol. 43, no. 4, pages 1523–1543, October 2007. 41, 42
- [Mahler 2007b] R. Mahler. *Unified Sensor Management Using CPHD Filters*. 10th International Conference on Information Fusion, 2007. 41, 82
- [Mallick 2002] Mahendra Mallick. *Maximum likelihood geolocation using a Ground Moving Target Indicator (GMTI) Report*. IEEE proceedings on the Aerospace conference, 2002. 15
- [Maskell 2002] S. Maskell et N. Gordon. *A tutorial on particle filters for on-line Non-linear/non-gaussian bayesian tracking*. ICIF, 2002. 47
- [Meviren 2004] Murat Meviren. *Système de reconnaissance de la parole revisité : réseaux bayesiens dynamiques et nouveaux paradigmes*. PhD thesis, Nancy I, 2004. 117, 245
- [Murphy 1999] Kevin Murphy et Saira Mian. *Modelling gene expression data using dynamic Bayesian networks*. Rapport technique, Lawrence Berkeley National Laboratory, 1999. 138, 241
- [Murphy 2002] K. Murphy. *Bayes net toolbox*. <http://www.cs.ubc.ca/~murphyk/Software/BNT/usage.html>, 2002. 135
- [Musicki 1994] D. Musicki, R. Evans et S. Stankovic. *Integrated probabilistic data association*. IEEE Transactions on Automatic Control, vol. 39, no. 6, pages 1237–1241, 1994. 56
- [N.A. Rota 2000] M. Thonnat N.A. Rota. *Activity recognition form video sequences using declaratives models*. European conference on artificial intelligence, 2000. 64
- [NATO 2007] NATO. *STANAG 4607 JAS (Edition 2) - NATO ground moving target indicator GMTI format*. 2007. 15
- [Nikovski 2000] D. Nikovski. *Constructing Bayesian networks for medical diagnosis from incomplete and partially correct statistics*. 2000. 138
- [Okello 2003] N. Okello et G. Thorns. *Threat assessment using Bayesian networks*. Proceedings of the Sixth International Conference of Information Fusion, vol. 2, pages 1102–1109, 2003. 61, 241
- [Olivier 1988] F. Olivier et P. Leray. *Etude comparative d'apprentissage de structures dans les réseaux bayesiens*. Morgan Kaufmann Publishers, 1988. 245
- [Olivier 2003] François Olivier. *De l'identification de structure de réseaux bayesiens à la reconnaissance de formes à partir d'informations complètes ou incomplètes*. PhD thesis, RJCIA, 2003. 117, 241
- [Orton 2002] M. Orton et W. Fitzgerald. *A Bayesian approach to tracking multiple targets using sensor arrays and particles filter*. IEEE Transactions on Signal Processing, 2002. 47
- [Pannetier 2004] B. Pannetier, K. Benameur, V. Nimier et M. Rombaut. *Ground moving target tracking with road constraint*. In Proceedings of SPIE, volume 5429, 2004. 99
- [Pannetier 2006a] B. Pannetier. *Data fusion for ground battlefield surveillance*. PhD thesis, University of Grenoble, 2006. 54, 94, 97, 123, 169, 175

- [Pannetier 2006b] B. Pannetier, V. Nimier et M. Rombaut. *Multiple Ground Target Tracking with a GMTI Sensor*. 9th International Conference on Information Fusion, 2006. 100
- [Pannetier 2007] B. Pannetier et M. Rombaut. *Terrain obscuration management for multiple ground target tracking*. 2007. 106
- [Pannetier 2008] B. Pannetier, J. Dezert et E. Pollard. *Improvement of Multiple Ground Targets Tracking with GMTI Sensor and Fusion of Identification Attributes*. IEEE Aerospace Conference, pages 1–13, March 2008. 103
- [Panta 2009] K. Panta, D.E. Clark et Ba-Ngu Vo. *Data Association and Track Management for the Gaussian Mixture Probability Hypothesis Density Filter*. IEEE Transactions on Aerospace and Electronic Systems, vol. 45, no. 3, pages 1003–1016, July 2009. 83
- [Pasha 2006] A. Pasha, B. Vo, H.D. Tuan et W.-K. Ma. *Closed Form PHD Filtering for Linear Jump Markov Models*. In 9th International Conference on Information Fusion, pages 1–8, July 2006. 74
- [Pasha 2009] S.A. Pasha, Ba-Ngu Vo, Hoang Duong Tuan et Wing-Kin Ma. *A Gaussian Mixture PHD Filter for Jump Markov System Models*. IEEE Transactions on Aerospace and Electronic Systems, vol. 45, no. 3, pages 919–936, July 2009. 74
- [Pearl 1988] J. Pearl. *Probabilistic Reasoning in Intelligent Systems : Networks of Plausible Inference*. Morgan Kaufmann Publishers, 1988. 117, 138, 241
- [Peterson 1981] J.L. Peterson. *Petri net theory and the modeling of systems*. Prentice Hall PTR Upper Saddle River, NJ, USA, 1981. 63
- [Pohl 1998] C. Pohl et JL Van Genderen. *Multisensor image fusion in remote sensing : concepts, methods and applications*. International journal of remote sensing, vol. 19, pages 823–854, 1998. 9
- [Pollard 2008a] E. Pollard, B. Pannetier et M. Rombaut. *A Particle-Filtering Approach to Convoy Tracking in the Midst of Civilian Trafic*. Signal Processing, Sensor Fusion, and Target Recognition XVII, vol. 6968, 2008. 44, 71
- [Pollard 2008b] Evangeline Pollard. *Pistage Multicible par l'utilisation des Ensembles Finis Aléatoires et de la Densité de Probabilité Jointe*. Rapport technique RT 1/13631, ONERA, 2008. 169
- [Pollard pear] E. Pollard, B. Pannetier et M. Rombaut. *Hybrid Algorithms for Multitarget Tracking using MHT and GMCPHD*. IEEE Transactions on Aerospace and Electronic Systems, to appear. 4, 107
- [Punithakumar 2008] K. Punithakumar, T. Kirubarajan et A. Sinha. *Multiple-model probability hypothesis density filter for tracking maneuvering targets*. IEEE Transactions on Aerospace and Electronic Systems, vol. 44, no. 1, pages 87–98, January 2008. 74
- [Rabiner 1989] Lawrence R. Rabiner. *A tutorial on hidden markov models and selected applications in speech recognition*. In Proceedings of the IEEE, pages 257–286, 1989. 62
- [Ramasso 2006] E. Ramasso, M. Rombaut et D. Pellerin. *A Temporal Belief Filter Improving Human Action Recognition in Videos*. In IEEE International Conference on Acoustics, Speech and Signal Processing, 2006. ICASSP 2006 Proceedings. 2006, volume 2, pages II–II, May 2006. 144

- [Ramasso 2007a] E. Ramasso, M. Rombaut et D. Pellerin. *State filtering and change detection using TBM conflict Application to human action recognition in athletics videos*. IEEE Transactions on Circuits and Systems for Video Technology, vol. 17, no. 7, page 944, 2007. 144
- [Ramasso 2007b] Emmanuel Ramasso. *Reconnaissance de séquences d'états par le modèle des croyances transférables. Application à l'analyse de vidéo d'athlétisme*. PhD thesis, Université Joseph Fourier, 2007. 27, 62
- [Reid 1979] Donald B. Reid. *An Algorithm for Tracking Multiple Targets*. IEEE Transactions on Automatic Control, vol. 24, pages 843–854, 1979. 50
- [Ristic 2004] B. Ristic, S. Arulampalam et N. Gordon. *Beyond the kalman filter - particle filters for tracking applications*. Artech House, 2004. 44
- [Rothrock 2000] Ronald L. Rothrock et Oliver E. Drummond. *Performance metrics for multiple-sensor multiple-target tracking*. volume 4048, pages 521–531. SPIE, 2000. 155
- [Salmond 1999] David J. Salmond et Neil J. Gordon. *Group and extended object tracking*. volume 3809, pages 284–296. SPIE, 1999. 71
- [Schubert 2004] J. Schubert, C. Martenson, H. Sidenbladh, P. Svenson et J. Walter. *Methods and System Design of IFD03 Information Fusion Demonstrator*. Cd Proc. Ninth Int. Command and Control Research and Technology Symp., 2004. 43
- [Schuhmacher 2008] D. Schuhmacher, B.-T. Vo et B.-N. Vo. *A Consistent Metric for Performance Evaluation of Multi-Object Filters*. IEEE Transactions on Signal Processing, vol. 56, no. 8, pages 3447–3457, Aug. 2008. 155, 158
- [Shafer 1976] G. Shafer. *A mathematical theory of evidence*. Princeton university press Princeton, NJ, 1976. 24
- [Sidenbladh 2003] H. Sidenbladh. *Multitarget Particle Filtering for the Probability Hypothesis Density*. 6th International Conference on Information Fusion, 2003. 43
- [Simani 2000] S. Simani et C. Fantuzzi. *Fault diagnosis in power plant using neural networks*. Information Sciences, vol. 127, no. 3-4, pages 125–136, 2000. 63
- [Simon 2002] D. Simon et Tien Li Chia. *Kalman filtering with state equality constraints*. Aerospace and Electronic Systems, IEEE Transactions on, vol. 38, no. 1, pages 128–136, jan 2002. 96
- [Simon 2007] C. Simon, P. Weber et E. Levrat. *Bayesian networks and evidence theory to model complex systems reliability*. Journal of Computers, vol. 2, no. 1, page 33, 2007. 138
- [Simone 2002] G. Simone, A. Farina, F. C. Morabito, S. B. Serpico et L. Bruzzone. *Image fusion techniques for remote sensing applications*. Information Fusion, vol. 3, no. 1, pages 3 – 15, 2002. 9
- [Singh 2004] Satnam Singh, H. Tu, J. Allanach, J. Areta, P. Willett et Krishna Pattipati. *Modeling threats*. IEEE Potentials, vol. 23, no. 3, pages 18–21, Aug.-Sept. 2004. 63, 241
- [Sittler 1964] R.W. Sittler. *An optimal data association problem in surveillance theory*. IEEE transactions on military electronics, vol. 8, no. 2, pages 125–139, 1964. 49
- [Smarandache 2004] F. Smarandache et J. Dezert. *Advances and applications of DSMT for information fusion : collected works*. American Research Press, 2004. 104

- [Smarandache 2005] F. Smarandache et J. Dezert. *Information fusion based on new proportional conflict redistribution rules*. In 2005 8th International Conference on Information Fusion, page 8, 2005. 104
- [Smets 1993] P. Smets. *Belief functions : The disjunctive rule of Combination and the Generalized Bayesian theorem*. International Journal of Approximate Reasoning, vol. 9, no. 1, pages 1–35, 1993. 138
- [Smets 2000] P. Smets. *Data fusion in the transferable belief model*. In Proceeding of the Third International Conference on Information Fusion, pages 10–13. Citeseer, 2000. 24
- [Smets 2002] P. Smets. *The application of the matrix calculus to belief functions*. International Journal of Approximate Reasoning, vol. 31, no. 1-2, pages 1–30, 2002. 26, 29, 31
- [Smets 2007a] P. Smets. *Analyzing the combination of conflicting belief functions*. Information Fusion, vol. 8, no. 4, pages 387–412, 2007. 32, 144
- [Smets 2007b] P. Smets et B. Ristic. *Kalman filter and joint tracking and classification based on belief functions in the TBM framework*. Information Fusion, vol. 8, no. 1, pages 16–27, 2007. 144
- [Soh 1999] L.K. Soh et C. Tsatsoulis. *Multisource data and knowledge fusion for intelligent SAR sea ice classification*. In Proceedings of the Int. Geoscience and Remote Sensing Symposium (IGARSS'98), pages 68–70. Citeseer, 1999. 9
- [Streit 1995] R.L. Streit, T.E. Luginbuhl et NAVAL UNDERWATER SYSTEMS CENTER NEWPORT RI. *Probabilistic multi-hypothesis tracking*. Rapport technique, 1995. 58
- [Synnergren 2009] J. Synnergren, B. Olsson et J. Gamalielsson. *Classification of information fusion methods in systems biology*. In Silico Biology, vol. 9, no. 3, pages 65–76, 2009. 9
- [Ulmke 2007] M. Ulmke, O. Erdinc et P. Willet. *Gaussian Mixture Cardinalized PHD Filter for Ground Moving Target Tracking*. International Conference on Information Fusion, 2007. 80, 103
- [USM 2001] *U.S. Marine Corps / Convoy operations handbook*, 2001. 13
- [Venkatasubramanian 1990] V. Venkatasubramanian, R. Vaidyanathan et Y. Yamamoto. *Process fault detection and diagnosis using neural networks*. Computers & Chemical Engineering, vol. 14, no. 7, pages 699–712, 1990. 63
- [Vermaak 2005] J. Vermaak, S.J. Godsill et P. Perez. *Monte Carlo filtering for multi-target tracking and data association*. IEEE Transactions on Aerospace and Electronic systems, vol. 41, no. 1, pages 309–332, 2005. 48
- [Vo 2003] Ba-ngu Vo et S. Singh. *Sequential Monte Carlo implementation of the PHD filter for multi-target tracking*. In In Proceedings of the Sixth International Conference on Information Fusion, pages 792–799, 2003. 43, 74
- [Vo 2005] B.-N. Vo, S. Singh et A. Doucet. *Sequential Monte Carlo methods for Multitarget filtering with Random Finite Sets*. IEEE Transactions on Aerospace and Electronic Systems, vol. 41, no. 4, pages 1224–1245, Oct. 2005. 43, 74
- [Vo 2006a] B.-T. Vo, B.-N. Vo et A. Cantoni. *Performance of PHD Based Multi-Target Filters*. 9th International Conference on Information Fusion, pages 1–8, July 2006. 39, 77, 80

- [Vo 2006b] Ba-Ngu Vo et Wing-Kin Ma. *The Gaussian Mixture Probability Hypothesis Density Filter*. IEEE Transactions on Signal Processing, vol. 54, no. 11, pages 4091–4104, Nov. 2006. 44
- [Vo 2006c] B.T Vo, B.N Vo et A. Cantoni. *Gaussian Mixture Cardinalized Probability Hypothesis Density Filter for Linear Gaussian Multi-Target Models*. IEEE, 2006. 74, 77, 80
- [Vo 2007] Ba-Tuong Vo, Ba-Ngu Vo et A. Cantoni. *Analytic Implementations of the Cardinalized Probability Hypothesis Density Filter*. IEEE Transactions on Signal Processing, vol. 55, no. 7, pages 3553–3567, July 2007. 37, 42, 43, 44, 74, 77, 82
- [Vo 2008] B.T. Vo. *Random Finite Sets in Multi-Object Filtering*. PhD thesis, University of estern Australia, 2008. 158
- [Wald 2004] A. Wald. *Sequential analysis*. Dover Pubns, 2004. 53, 99
- [Waxman 2004] M.J. Waxman et O.E. Drummond. *A bibliography of cluster (group) tracking*. In Proceedings of SPIE, volume 5428, page 551, 2004. 70
- [Weber 2004] P. Weber et M.C. Suhner. *Modélisation de processus industriels par Réseaux Bayésiens Orientés Objet (RBOO)-Application à l'analyse des performances d'un processus industriel*. Revue d'intelligence artificielle, vol. 18, pages 299–326, 2004. 117
- [Williams 2003] J.L. Williams et P.S. Maybeck. *Cost-Function-Based gaussian mixture reduction for target tracking*. ISIF, 2003. 54
- [Wiskott 1997] L. Wiskott, J.M. Fellous, N. Krüger et C. Von der Malsburg. *Face recognition by elastic bunch graph matching*. In Computer Analysis of Images and Patterns, pages 456–463. Springer, 1997. 58
- [Wittenbrink 1996] C.M. Wittenbrink, G.G.J. Langdon et G. Fernandez. *Feature extraction of clouds from GOES satellite data for integrated model measurement visualization*. In Proceedings of SPIE - The International Society for Optical Engineering., volume 2666, pages 212–222. Citeseer, 1996. 9
- [Xu 1996] H. Xu et P. Smets. *Reasoning in evidential networks with conditional belief functions*. International Journal of Approximate Reasoning, vol. 14, no. 2-3, pages 155–185, 1996. 117, 138
- [Yaghlane 2008] B.B. Yaghlane et K. Mellouli. *Inference in directed evidential networks based on the transferable belief model*. International Journal of Approximate Reasoning, vol. 48, no. 2, pages 399–418, 2008. 141
- [Zadeh 1965] L.A. Zadeh. *Fuzzy sets*. Information and Control, vol. 8, no. 3, pages 338 – 353, 1965. 22
- [Zhang 2009] Hongjian Zhang, Zhongliang Jing et Shiqiang Hu. *Gaussian mixture CPHD filter with gating technique*. Signal Processing, vol. 89, no. 8, pages 1521 – 1530, 2009. 79
- [Zweig 1998] G. Zweig et S. Russell. *Speech recognition with dynamic Bayesian networks*. In Proceedings of the national conference on artificial intelligence, pages 173–180. John Wiley & sons LTD, 1998. 241

Liste des publications

Journaux internationaux

E. Pollard, B. Pannetier and M. Rombaut, *Hybrid Algorithms for Multitarget Tracking using MHT and GMCPHD*, IEEE Transactions on Aerospace and Electronic Systems, to appear

Conférences internationales avec comité de lecture

E. Pollard, B. Pannetier and M. Rombaut, *Convoy detection processing by using the hybrid algorithm (GMCPHD/VS-IMMC-MHT) and dynamic bayesian networks*, 12th International Conference on Information Fusion, 2009, Seattle, WA, USA

Best Student Paper

E. Pollard, A. Plyer, B. Pannetier, F. Champagnat and G. Le Besnerais *GM-PHD filters for multi-object tracking in uncalibrated aerial videos*, 12th International Conference on Information Fusion, 2009, Seattle, WA, USA

E. Pollard, M. Rombaut and B. Pannetier, *Bayesian networks vs. Evidential network. An application to convoy detection.*, Information Processing and Management of Uncertainty (IPMU), Dortmund, Germany, 2010

E. Pollard, B. Pannetier and M. Rombaut, *Performances in Multitarget Tracking for Convoy Detection over Real GMTI data*, 13th International Conference on Information Fusion, Edinburgh, 2010

B.Pannetier, J. Dezert, **E. Pollard**, *Improvement of Multiple Ground Targets Tracking with GMTI Sensor and Fusion of Identification Attributes*, IEEE Aerospace Conference, 2008, Big Sky, USA

Conférences nationales avec comité de lecture

E. Pollard, M. Rombaut and B. Pannetier, *Un nouvel algorithme de pistage multible utilisant les Ensembles Finis Aléatoires. Application à la détection de convoi de véhicules*, XXIIe colloque GRETSI (traitement du signal et des images), Dijon (FRA), 8-11 septembre 2009

Conférences internationales sans comité de lecture

E. Pollard, B. Pannetier and M. Rombaut, *A Particle-Filtering Approach to Convoy Tracking in the Midst of Civilian Traffic*. SPIE Signal Processing, Sensor Fusion, and Target Recognition XVII, vol-6968, 2008, Orlando, FL, USA