



HAL
open science

Détection de comportements à travers des modèles multi-agents collaboratifs, appliquée à l'évaluation de la situation, notamment en environnement asymétrique avec des données imprécises et incertaines

Jérémy Patrix

► **To cite this version:**

Jérémy Patrix. Détection de comportements à travers des modèles multi-agents collaboratifs, appliquée à l'évaluation de la situation, notamment en environnement asymétrique avec des données imprécises et incertaines. Intelligence artificielle [cs.AI]. Université de Caen, 2013. Français. NNT : . tel-00991091

HAL Id: tel-00991091

<https://theses.hal.science/tel-00991091v1>

Submitted on 14 May 2014

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

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

Université de Caen Basse-Normandie

École doctorale SIMEM

Thèse de doctorat

présentée et soutenue le : 12/12/2013

par

Jérémy Patrix

pour obtenir le

Doctorat de l'Université de Caen Basse-Normandie

Spécialité : Informatique et applications

**Détection de comportements à travers des modèles multi-agents
collaboratifs, appliquée à l'évaluation de la situation, notamment en
environnement asymétrique avec des données imprécises et incertaines.**

Directeur de thèse : *Abdel-Ilhah Mouaddib*

Jury

Amal El Fallah Seghrouchni, Professeur, LIP6, Univ. Pierre et Marie Curie (rapporteur)
Nicolas Sabouret, Professeur, LIMSIS & Supelec, Univ. Paris-Sud (rapporteur)
René Mandiau, Professeur, LAMIH, Univ. Valenciennes (président)

Abdel-Ilhah Mouaddib, Professeur, GREYC, Univ. Caen Basse-Normandie (directeur de thèse)
Stephan Brunessaux, Senior Expert, IPCC, Cassidian (an EADS company) (encadrant)
Simon Le Gloanec, Ingénieur de Recherche, IPCC, Cassidian (encadrant)
Dafni Stampouli, Ingénieur de Recherche, IPCC, Cassidian (encadrant)

Mis en page avec la classe thloria.

Remerciements

Je tiens à exprimer mes remerciements pour tous ceux qui m'ont permis de produire ce manuscrit de thèse Cifre. J'espère qu'il ajoute une pierre de plus à l'édifice de la recherche universitaire et de l'innovation en entreprise. Parmi vous, j'ai ressenti un immense plaisir à partager les aventures qu'offre ce monde. Vous m'avez formé (et j'espère avoir participé) à vos connaissances, à vos formalismes, à vos idées, à vos approches, à vos méthodes, à vos techniques, à vos innovations, à vos outils, à vos solutions, à vos critiques, à vos corrections,... et à votre bonne humeur.

Ces trois années de thèse Cifre sont déjà terminées et me seront nostalgiques. J'ai travaillé à vos côtés sur les fronts ingénieur et chercheur. Même si je suis maintenant un autre chemin, j'ai pris goût à vous partager (et breveter) les idées de ma thèse. Je continuerais à innover en développant et expérimentant mes idées. Vos conseils, vos soutiens, vos encouragements et vos encadrements portent une responsabilité dans le jeune expert et le jeune inventeur que je suis devenu, alors que je n'étais que développeur à l'origine. J'en chéris encore plus ce merveilleux domaine de l'I.A.

Le sentiment d'avoir réussi ou atteint une nouvelle étape m'a toujours été éphémère. Je souhaite donc remercier ceux qui m'ont toujours interloqué sur ce que j'ai pu accomplir par leur soutien, leur amitié et l'environnement qu'ils m'ont apportés : (présenté par ordre semi-aléatoire rétrospectif)

- Dafni S., Marc C., Abdel-illah M., Stephan B., Simon L.G., Sylvain G., Xavier L., Jean H., Patrick G.,...

- Xavier D., Caroline C., Amandine B., Laurie S., Nicolas L.G., Clément C., Arnaud S., Jennifer R., Guillaume D., Rémi G., Vincent B., Yann M., Romain N., Emilien B., Luc M., Jérémie D., Gérard D., Sylvie B., Khaled K., Frédéric P., Bruno G., Marie-Angèle P., Kei-Leo B., Arthur V-L., Esther N.,...

- Mon jury de thèse : Amal El Fallah Seghrouchni, René Mendiau et Nicolas Sabouret.

- Les partenaires de l'horizon universitaire, des projets européens, de la vie en entreprise,... qui ont été des rencontres scientifiques et amicales.

- Les institutions qui ont subventionné ces travaux.

- Les pauses croissants / danses latines / soleil / resto / boissons / ...

- Ma famille qui m'a toujours rappelé que peu importe les voies et les choix que je suivais ou stoppais, tant que c'était pour moi un plaisir de les vivre.

- Ces personnes qui m'ont fait prendre conscience de mes aptitudes et m'ont poussé.

Par vos interactions, je suis maintenant diplômé d'un doctorat et je peux enfin répondre "Oui ! mais en informatique" quand quelqu'un demande s'il y a un docteur dans la salle.

Ce document et son contenu sont la propriété de CASSIDIAN et ne doit pas être copié ni diffusé sans autorisation. Toute utilisation en dehors de l'objet expressément prévu est interdite.

Il est strictement interdit de reproduire, distribuer et utiliser le contenu de ce document sans l'autorisation préalable de l'auteur. Les contrefacteurs seront jugés responsables pour le paiement des dommages. Tous droits réservés y compris pour les brevets, modèles d'utilité, dessins et modèles enregistrés.

Copyright© 2013 - CASSIDIAN - Tous droits réservés.

Table des matières

Préambule	1
1 Contexte	3
2 Problématique	6
3 Organisation du manuscrit de thèse	6
I Modèles pour la Détection de Comportements Multi-Agents	9
Introduction	11
1 Comportements Collectifs	13
1.1 Point de vue sociologique	14
1.1.1 Théories portant sur les comportements collectifs	14
A. Théorie de la contagion sociale	14
B. Théorie de la convergence sociale	16
C. Théorie des normes émergentes	16
D. Théorie de la valeur ajoutée	17
E. Foules et Mouvements Sociaux	18
1.1.2 Théories portant sur les groupes	18
A. Notion de proxémie	19
B. Caractéristiques d'un groupe	20
C. Primitives d'interactions locales de groupe	21
1.1.3 Appropriation par les approches d'intelligences artificielles	21
1.2 Micro vs Méso vs Macro : Trois niveaux de modélisations	23
1.2.1 Micro - Individus par des agents	24
1.2.2 Macro - Foule par un système multi-agents	25
A. Structure organisée	25
B. Stimuli communs d'une foule	26
1.2.3 Méso - Groupes par des systèmes bio-inspirés	28

A.	Notion de flocking	28
B.	Systèmes à base de phéromones	29
1.3	Conclusion	29
2	Évaluation de la Situation par la Fusion de Données	31
2.1	Évaluation de situation asymétrique	32
2.1.1	Situations asymétriques	32
A.	Contexte de l'asymétrie	32
B.	Comportements récurrents dans les environnements asymétriques	33
C.	Formalisme d'une situation évaluée	34
2.1.2	Origine de la fusion de données	36
A.	Sources des données : des capteurs de surveillance	37
B.	Modèle JDL de fusion de données	38
2.2	Identification des groupes et des comportements déviants	41
2.2.1	Suivi de multiple personnes	41
A.	Pistage de groupe	42
B.	Reconnaissance d'équipe	44
C.	Centroïde, une modélisation de groupe	47
2.2.2	Comportements déviants (anormaux, inattendus et suspicieux)	48
2.2.3	Traitement des événements complexes	49
2.3	Conclusion	52
3	Apprentissage et Reconnaissance des Comportements	53
3.1	Premiers travaux	54
3.2	Modèle de Markov caché	55
3.2.1	Définition du HMM	55
3.2.2	Informations utiles pour la définition des états	57
3.2.3	Récapitulatif des extensions du HMM	58
3.3	Décomposition de l'espace des paramètres	63
A.	Décomposition par la discrétisation des états	63
B.	Décomposition des observations	63
C.	Décomposition en couches	64
D.	Décomposition et agrégation des informations	65
E.	Conclusion pour la décomposition des comportements simples	66
3.4	Hiérarchisation des comportements	66
I.	Hiérarchie à base de grammaires stochastiques	67
II.	Hiérarchie à base de décisions stochastiques hiérarchisées	68

III.	Hiérarchie adaptée au groupe d'agents	69
IV.	Hiérarchie factorisée pour réduire l'explosion du nombre d'états	70
V.	Hiérarchie adaptée pour les séquences d'activités à long terme	71
VI.	Hiérarchie adaptée au système multi-agent	71
VII.	Conclusion pour la hiérarchisation des comportements abstraits	72
Conclusion		73
II	Modèles de Comportements Collectifs : Détection Micro, Méso et Macro	75
	Introduction	77
4	Détection Macro d'une Simulation Micro : Application à la foule en panique	79
4.1	Micro - Modélisation des agents	80
4.1.1	Agent - Algorithme de décision de sa direction	80
4.1.2	Architecture BDI - Croyances, Désirs, Intentions	81
4.2	Détection des activités collectives de panique	82
4.2.1	Macro - Apprentissage des mouvements de foules	83
	A. Apprentissage des chemins empruntés par les agents	83
	B. Apprentissage des interactions physiques	84
4.2.2	Micro - Anticipation des chemins individuels	86
4.3	Conclusion	87
5	Méso - Détection des Comportements Collectifs Objectivés	89
5.1	Décomposition par les états relatifs discrétisés	90
5.1.1	État fusionné d'un groupe	91
5.1.2	État relatif discrétisé d'un groupe envers un objectif	92
5.1.3	Séquencement d'un comportement objectivé par des états relatifs discrétisés	94
5.2	Identification des groupes	94
5.2.1	Micro → Méso - Approche par la proxémie et les séquences d'états relatifs	95
5.2.2	Macro → Méso - Approche par la proxémie et l'utilité de groupe	97
5.3	Assignment des comportements objectivés aux groupes	99
5.4	Estimation des intentions	100
5.4.1	Intentions par l'évaluation des comportements objectivés sur le long terme	101
5.4.2	Intentions par les états objectivés discrétisés	102
5.5	Conclusion	104
Conclusion		105

III	Expérimentations : Simulation Micro et Détection Macro vs Méso	107
6	Micro - Simulation d'une Foule en Panique	109
6.1	Implémentation logicielle	109
6.2	Expériences n° 1 : Mouvements de foule	111
6.3	Conclusion	113
7	Macro - Identification, Apprentissage, et Anticipation des Mouvements de Panique	115
7.1	Expériences n° 2 : Apprentissage des mouvements récurrents	117
7.2	Expériences n° 3 : Localisation des risques liés à la panique collective	117
7.3	Expériences n° 4 : Anticipation des mouvements collectifs	119
7.4	Expériences n° 5 : Comportements face à des agents menaçants	120
7.5	Conclusion	121
8	Méso - Détection de Comportements Objectivés de Groupe	123
8.1	Identification des groupes	124
8.1.1	Expériences n° 6 : Groupes en présence de multiples objectifs fixes	125
8.1.2	Expériences n° 7 : Multiples groupes en l'absence d'objectifs fixes	126
8.2	Apprentissage de HMM de comportements objectivés	131
8.2.1	Expériences n° 8 : En se basant seulement sur la position et la vitesse	131
8.3	Reconnaissance : HMM versus CEP	134
8.3.1	Expériences n° 9 : Détection dans un scénario complexe	135
8.3.2	Expériences n° 10 : Précision sur divers environnements asymétriques	136
8.4	Détection de menaces dans un environnement complexe dynamique	141
8.4.1	Expériences n° 11 : Identification d'un agent menaçant parmi une foule	142
8.5	Conclusion	144
IV	Conclusion et futurs travaux	147
	Bilan des travaux	149
	Perspectives	151
1	Jeux stochastiques cachés	151
1.1	Notions contextuelles	152
1.2	Modèle	153
	A. Multi-HMM pour la détection des possibles comportements d'un agent	153
	B. HSG pour la détection des possibles comportements multi-agents	154
1.3	Conclusion	155

Bibliographie	157
V Annexes	165
9 Le projet EUSAS	167
9.1 Historique	167
9.2 Implémentations	168
9.2.1 SG - Serious Game component	173
A. Interface utilisateur de VBS2	173
B. Communication bidirectionnelle en entrée/sortie de VBS2	175
9.3 Expérimentations	175
9.3.1 Scénario asymétrique n° 1 - Civils mécontents devant une base militaire	176
9.3.2 Scénario asymétrique n° 2 - Patrouille face au pillage d'un magasin	176
9.4 Conclusion	179
10 Le projet DEM@CARE	181
10.1 Introduction	182
10.1.1 Contexte clinique	182
10.1.2 Objectif	183
10.2 Système Dem@care	183
10.2.1 Composants et leurs niveaux	184
10.2.2 Intégration des composants en services web	186
10.2.3 Dans le FusionLab de notre équipe IPCC de Cassidian	187
10.2.4 Analyse produite des activités quotidiennes	188
10.3 Conclusion	189

Table des figures

1	Les comportements collectifs des scénarios asymétriques : des foules en panique et des émeutes.	4
1.1	Diagramme des sphères proxémiques dans les pays occidentaux.	19
1.2	Les primitives d'interactions locales parmi les comportements internes aux groupes.	22
1.3	Une situation simulée est observable sur trois niveaux de modélisation : macro pour la foule, méso pour les groupes et micro pour les individus.	24
1.4	Une structure de système multi-agents	26
1.5	Le modèle d'Helbing appliqué	27
1.6	Le modèle SCT appliqué	28
1.7	Les règles du flocking	29
2.1	Le modèle d'évaluation de la situation	35
2.2	Le modèle de fusion de données révisé et recommandé	39
2.3	Le centroïde CRPV avec une équipe de trois agents	48
2.4	Le traitement d'événements complexes sur le modèle JDL de fusion de données	50
3.1	Un HMM.	56
3.2	Les différentes approches pour la modélisation de comportements simples à titre de comparaison de leur complexité : HMM, MOHMM, PaHMM, CHMM, DML-HMM	59
3.3	Les différentes approches pour la modélisation de comportements simples à titre de comparaison de leur complexité : FHMM, HMDT, LHMM, CHMM, ODHMM, LHMM, BHMM	60
3.4	Les différentes approches pour la modélisation de comportements abstraits à titre de comparaison de leur complexité : AHMM, FS-AHMM, AHMEM, M-AHMEM	61
3.5	Les différentes approches pour la modélisation de comportements hiérarchisés à titre de comparaison de leur complexité : HMMP, HHMM, S-HSMM, HHMM-JPDAF	62
4.1	Les comportements des agents pour chacune de leur récompense.	82
4.2	L'ensemble des sous-états $q_{x,y}^j$ pour chaque état q_i possible si chaque état comporte neuf états voisins (s'incluant lui-même)	85
4.3	Un exemple de probabilités de transitions dans l'état $q_i = \{q_i^1, \dots, q_i^{17}, \dots\}$ après apprentissage	86
4.4	Le chemin le plus probable d'un agent parmi un ensemble de positions	87
5.1	Le processus pour calculer un état relatif discrétisé à partir d'un ensemble d'états observables de n agents d'un groupe c et d'un objectif g	93
6.1	Vue 2D d'une carte simulée	110

6.2	Déroulement d'une itération avec 300 agents paniqués (à t = 0, 5, 10, 15, 20, 25 secondes)	112
7.1	Les chemins récurrents et leurs directions empruntés par les agents lors d'une perception normale et limitée après l'apprentissage des comportements issus des multiples itérations de la simulation.	116
7.2	Illustration des moments allant du simple frôlement physique aux bousculades et piétinements.	118
7.3	Anticipation en temps réel des chemins les plus probables que les agents paniqués vont suivre.	119
7.4	Un comportement de groupe pris entre deux agents menaçants	121
8.1	Légende des vues 2D	124
8.2	Identification de groupes par notre algorithme en présence de divers objectifs fixes	125
8.3	Vue de VBS2 en 2D/3D de 13 groupes parmi 100 agents en mouvement	127
8.4	Vue 2D de notre implémentation des 13 groupes parmi 100 agents en mouvement	128
8.5	Identification par notre approche des 13 groupes parmi 100 agents en mouvement	129
8.6	Identification par notre approche des 13 groupes parmi 100 agents en mouvement	130
8.7	Exemples de HMMs appris de comportements objectivés de groupe	133
8.8	Une détection de niveau méso dans un scénario complexe	136
8.9	Exemples de scénarios surveillés pour obtenir la précision de la reconnaissance.	137
8.10	Un scénario asymétrique dangereux : un kamikaze introuvable parmi la foule paniquée.	141
8.11	Identification d'un agent menaçant en utilisant les comportements collectifs de la foule.	143
1	Un exemple de différents HMMs appris	153
9.1	Les composants principaux du système EUSAS	169
9.2	Interface graphique de la plateforme ABS (Agent-Based Simulator)	170
9.3	Interface graphique de la plateforme BC (Behaviour Cloning component)	171
9.4	Vue 2D/3D de VBS2 (intégré dans le composant SG).	172
9.5	Implémentations dans le simulateur VBS2.	174
9.6	Scénario asymétrique n° 1 dans VBS2.	177
9.7	Scénario asymétrique n° 2 dans VBS2.	178
10.1	Processus général du projet DEM@CARE	181
10.2	Services web du 1 ^{er} prototype du système Dem@care	185

Liste des tableaux

1.1	Les six causes déterminantes, nécessaires et suffisantes pour qu'un mouvement social émerge	17
2.1	Observation micro, méso et macro d'une représentation d'un comportement basée sur les méthodes de suivi multi-cibles.	42
5.1	Des symboles décrivant des comportements objectivés de groupes en fonction du type d'objectifs	102
7.1	Qualité des prévisions des transitions d'états que les agents vont exécuter (après l'apprentissage de 1000 itérations).	120
8.1	Comparaison de la précision entre HMM et CEP de la détection des comportements objectivés de groupe	138

Préambule

1 Contexte

Cette dernière décennie, il s'est produit un nombre croissant d'événements de type rassemblements sociaux, ce qui augmente le risque lié aux problèmes de sécurité. Nous pouvons rappeler l'exemple des vingt et une personnes qui ont péri lors de l'événement appelé la *Love Parade* le 24 juillet 2010 à Duisburg en Allemagne (i.e. Figure 1(a) page 4). Lors du passage dans un tunnel, des participants se sont retrouvés compressés par manque de place et se sont mis à se bousculer. Une **panique collective** s'est déclenchée malgré la présence d'une force de sécurité qualifiée qui n'a pu réagir face un tel **phénomène collectif émergent**. En somme, la détection de comportements collectifs serait **une aide inestimable** pour diminuer les dommages, blessés et décès se produisant durant des situations asymétriques telles qu'une panique collective.

Les photographies suivantes de la Figure 1 représentent directement le contexte du sujet de cette thèse, qui a été créée dans le cadre du projet **EUSAS** (*European Urban Simulation for Asymmetric Scenarios*, i.e. ¹ *Simulation Urbaine Européenne de Scénarios Asymétriques*) présenté en annexe 9 page 167. Ce projet a été mis en place pour tester et démontrer une nouvelle solution face aux problèmes dans les photographies 1 que rencontrent les forces de sécurité. Ce projet a été financé par 20 nations par l'intermédiaire du JIP FP (*Joint Investment Programme Force Protection*) de l'EDA (*Agence Européenne de Défense*).

Cette thèse CIFRE (*convention industrielle de formation par la recherche*) a été produite de novembre 2010 à octobre 2013 en étroite collaboration avec :

▷ L'équipe dirigée par **Stéphan Brunessaux** (*Senior Expert*) du département **IPCC** (*Information Protocol Control and Cognition*) dans la section SDC (*System Design Center*) de **Cassidian**, la filiale "défense et sécurité" d'**EADS** (*European Aeronautic Defence and Space Company*). En 2010, Cassidian se nommait *EADS Defense & Security*, et sera nommé *Airbus Defense and Space* à partir de 2014.



▷ L'équipe **MAD** (*Model, Agent, Decision*) du laboratoire **GREYC** (*Groupe de recherche en informatique, image, automatique et instrumentation de Caen*) de l'Université de Caen Basse-Normandie (France).

L'équipe IPCC a accueilli l'auteur de cette thèse, **Jérémy Patrix**, en tant qu'**ingénieur de recherche** à Cassidian (Val-de-Reuil, France). Ce nom de poste est dû aux trois pôles d'encadrement de l'auteur durant cette thèse CIFRE :

1. Le pôle **recherche** : encadré par le directeur de thèse **Abdel-Ilhah Mouaddib** (de l'équipe MAD).

2. Le pôle **innovation** : encadré successivement par **Sylvain G.** puis **Simon L.G.** (docteur), tous deux employés comme ingénieurs de recherche dans l'équipe IPCC.

3. Le pôle **ingénieur** : dirigé successivement par **Marc C.** puis **Dafni S.**, tous deux titulaires d'un doctorat et employés comme manager de recherche dans l'équipe IPCC. Jérémy Patrix a pu ainsi travailler sur deux projets européens (présentés en annexe 9 page 167 et 10 page 181) en collaboration avec différents partenaires européens. Ces projets sont une principale ressource de financement de l'équipe IPCC et une source d'inspiration pour la recherche et l'innovation pour les membres d'IPCC.

1. Du latin *id est*, nous utiliserons la notation "i.e." pour signifier "c'est-à-dire" tout au long du manuscrit.



(a) *Love Parade*, le 24 juillet 2010 à Duisburg en Allemagne - 511 personnes blessées et 21 morts lors de mouvements de foule dans un tunnel menant au lieu du festival. Les participants ont paniqué à cause des étouffements lors de la compression des corps. Cet événement a mis fin à ce rassemblement annuel (Source : 20minutes.fr).



(b) Une panique de masse à Chongqing en Chine, le 5 juin 1941 - Pendant un raid aérien japonais, 4000 personnes sont mortes par piétinements ou étouffements en rejoignant les abris (Source : commons.wikimedia.org).



(c) Attentat lors du 1er Marathon de Boston - Une explosion provoque une fuite de la foule (Source : commons.wikimedia.org).



(d) Émeute lors d'un match de football à Port-Saïd en Égypte - Au moins 30 personnes tuées et plus de 300 blessées lors de violents heurts (Source : huffingtonpost.fr).



(e) Des émeutes (extraits du projet EUSAS en Annexe 9 page 167)

FIGURE 1 – Les comportements collectifs des scénarios asymétriques : des foules en panique et des émeutes.

À l'origine, le projet EUSAS a été gagné par l'appel à proposition de l'équipe IPCC dont le résultat devait porter sur les thèmes capacitaires - « *Système de communication sans fil tactique sécurisée en environnement urbain* » et « *Planification de mission et formation dans un environnement asymétrique* » - à travers les six domaines technologiques suivants :

1. *FP/Cap 4 - R&T Goal 11 : Contrôle intelligent des communications téléphoniques mobiles antagonistes.*
2. *FP/Cap 5 - R&T Goal 12 : Identification améliorée des menaces par une meilleure modélisation des comportements des : a) individus, b) foules, en faisant la distinction entre le comportement planifié ou ciblé d'individus (terroriste, poseur de bombe, tireur isolé) et le comportement spontané des foules (émeutes, panique).*
3. *FP/Cap 5 - R&T Goal 13 : Possibilités d'automatisation de la détection et de la réponse, place de « l'homme dans la boucle » : pour une meilleure identification des menaces par un meilleur usage de la modélisation du comportement des foules et des individus et une meilleure modélisation des menaces asymétriques.*
4. *FP/Cap 5 - R&T Goal 14A : Fournir un outil de planification de mission et de répétition ou de formation au niveau tactique, basé sur des informations exactes et récentes, facilement mis à jour, transportable, interactif et convivial. Étudier les méthodes permettant de mettre à jour rapidement les données géographiques et autres concernant l'environnement de la mission dans l'outil, en y incluant les données des capteurs en temps réel.*
5. *FP/Cap 5 - R&T Goal 14B : Étudier les méthodes de formation et les techniques à employer en conjonction avec des outils de planification ou de formation améliorés. Étudier l'utilité de la mise en réseau (jeux) et du jeu de rôle.*
6. *FP/Cap 5 - R&T Goal 15 : Amélioration des modèles de menaces asymétriques : a) éléments génériques d'asymétrie, b) éléments d'asymétrie spécifiques à la mission.*

Nous retrouvons dans les objectifs (*Goals*) 12 et 13, la source d'inspiration du sujet de cette thèse.

"Détection de comportements à travers des modèles multi-agents collaboratifs, appliquée à l'évaluation de la situation, notamment en environnement asymétrique avec des données imprécises et incertaines."

Les comportements multi-agents collaboratifs impliquent qu'il est question de comportements collectifs. Il est donc nécessaire de définir ce que sont les comportements collectifs. Les théories sociologiques sont exploitables à ce propos afin de comprendre comment des comportements collectifs peuvent se produire, tels que ceux présentés sur les photographies page 4.

L'obtention de données de comportements collectifs est un problème récurrent dans le domaine de recherche de la détection. Sans elles, il est difficile de tester une quelconque méthode de détection. La solution serait de les produire par une simulation virtuelle, mais il reste à savoir comment et sur quel niveau d'observation. Une contrainte supplémentaire est qu'elles doivent être produites comme issue d'un système de surveillance, d'où le besoin de méthodes pouvant gérer des données d'observations imprécises et incertaines qui seraient issues de capteurs.

Pour ce qui est de l'évaluation de la situation en environnement asymétrique, une détection automatique est nécessaire pour comprendre le déroulement de la situation asymétrique. L'asymétrie est devenue ces dernières années un enjeu majeur dans les affrontements collectifs de notre époque. Ceux-ci doivent sans doute produire des comportements collectifs récurrents et spécifiques à ce genre d'environnement.

2 Problématique

Les comportements collectifs provoquent des problèmes que les forces de sécurité ont de grandes difficultés à gérer. Ils ont les capacités pour aider, mais ils leur manquent les informations nécessaires pour qu'ils décident de leurs actions. **Notre solution** est de fournir un appui logistique qui **rend compte de la situation** en temps réel. Un système de surveillance multi-capteurs peut nous permettre d'obtenir des données de la situation. Toutefois, ces données sont imprécises, incertaines et peuvent être issues de différents types de capteurs, alors est-il envisageable de les **fusionner** pour une meilleure qualité ?

Afin de déterminer quelle est la meilleure approche de détection, quelques données ne seront pas suffisantes pour obtenir de réelles statistiques sur la qualité des résultats. **La simulation** offre l'avantage de pouvoir produire à volonté des données issues d'**environnements asymétriques**, mais certaines questions subsistent : Quelles sont les **théories sociologiques** qui nous permettent de **modéliser** des comportements collectifs ? Quel est le **niveau** de modélisation : devons-nous simuler la foule en un seul bloc (**macro**), en plusieurs groupes (**méso**) ou chaque agent individuellement (**micro**). Un bas niveau de modélisation est avantageux pour avoir l'aspect le plus réel possible, mais comment réduire la complexité des calculs d'un tel **système multi-agent** ?

Nous désirons détecter les comportements collectifs. Toutefois, les trois niveaux de détection (micro, méso, macro) restent les mêmes que pour la simulation abordée précédemment. Quels sont les avantages et les limites de chaque niveau ? **Les approches multi-agents collaboratives** peuvent-elles aussi nous permettre de réduire la complexité des calculs ? Quand nous parlons de détection, quels en sont les différentes formes : un comportement collectif peut-il être identifié et classifié, **appris et reconnu**, anticipé et modifié ? Est-il envisageable de détecter des informations **de haut niveau** telles que les groupes, leurs comportements, leurs objectifs et leurs intentions ? Afin de prendre en compte l'incertitude des données, pouvons-nous disposer d'approches estimant **les probabilités** de détection de tels faits ?

Pour répondre aux questions que nous venons d'aborder, la section suivante présente le plan que nous avons suivi dans ce manuscrit de thèse.

3 Organisation du manuscrit de thèse

Afin de répondre à notre problématique, la première partie présente notre état de l'art, la deuxième notre modèle suivi d'une troisième partie sur nos expérimentations. Après la conclusion, nous présenterons les projets européens qui ont servi de contexte à cette thèse, notamment pour les expérimentations.



Notre état de l'art porte principalement sur les modèles permettant la détection des comportements multi-agents. Celui-ci est divisé en trois chapitres.

Les **comportements collectifs** sont le sujet du premier chapitre. Les **théories sociologiques** sur les foules, les mouvements sociaux et les groupes ont été appliquées en **intelligence artificielle** afin de les simuler virtuellement sur différents niveaux de modélisation : **micro** pour les individus, **méso** pour les groupes et **macro** pour la foule.

La **fusion de données** représente l'idée principale du chapitre 2. Celui-ci explique comment un système peut **évaluer une situation** en s'appuyant sur cette **fusion** afin d'extraire des **informations de haut**

niveau. Le terme d'**asymétrie** est présenté afin de nous concentrer sur les méthodes d'identification des **groupes** et des **comportements déviants** qui sont les comportements collectifs de ces **environnements asymétriques**. Dans le procédé de la fusion de données, le **suivi** des multiples entités et groupes observés nous permet de déclencher des alertes lors d'**événements complexes** tels que les débordements (comportements déviants) que des forces de sécurité chercheraient à éviter (e.g. ² les photographies page 4).

La limitation des méthodes d'identification, capable d'alerter d'une anomalie, mais pas de reconnaître une situation, nous a amenés à étudier les solutions d'**apprentissage** et de **reconnaissance** au chapitre 3. Plusieurs travaux ont été menés dans ce domaine, toutefois le modèle de Markov caché s'est approprié toutes les innovations de ce domaine pour être étendu à de nouveaux modèles. En résumé, un comportement simple est **décomposé** afin de l'apprendre. Dans le cas d'un comportement complexe, il est **hiérarchisé** sur les différents **niveaux d'observations**.



Nous présentons en deuxième partie notre **modèle multi-agents de détection des comportements collectifs** s'appliquant différemment sur les trois niveaux d'observations **micro, méso et macro**.

Nous présentons, en chapitre 4, une **détection macro** d'une **simulation micro**. En d'autres termes, nous **simulons** des agents individuellement dans un environnement virtuel que nous maîtrisons. La deuxième étape est l'**apprentissage macro** des **comportements collectifs** (de panique dans notre cas) afin de nous permettre de les **anticiper en temps réel**.

Le *comment* d'un comportement collectif est intégré dans les modèles qui nous permettent de les détecter, mais jamais le *pourquoi*. Le chapitre 5 présente notre **innovation brevetée** au niveau méso qui consiste à apprendre et reconnaître les **comportements objectivés** de groupe (i.e. envers un objectif). Nous avons créé une nouvelle donnée appelée **état relatif discrétisé**. Celui-ci nous permet de séquencer le comportement qu'un groupe effectue envers n'importe quelle autre entité de la situation afin d'en extraire l'**objectif**. Nous nous sommes aperçus que son application pouvait aussi être utilisée pour **identifier les groupes** et les intentions en analysant les **comportements relatifs**.



Nous arrivons aux **expérimentations** en troisième partie qui porte sur notre **simulation micro** et notre **détection macro** et surtout **méso**. L'implémentation logicielle et les résultats de la simulation **micro** d'une foule en panique sont expliqués au chapitre 6. L'identification, l'apprentissage et l'anticipation des mouvements de paniques au niveau **macro** s'effectuent en trois expériences du chapitre 7. La détection des comportements objectivés au niveau **méso** à travers cinq expériences est incluse dans le chapitre 8.



Finalement, une conclusion est réalisée à propos de nos **travaux passés** et **futurs** autour du sujet de cette thèse. Suite à cela, les projets européens **EUSAS** (pour la simulation de comportements de foules en scénarios asymétriques) et **DEM@CARE** (pour la détection des activités quotidiennes de personnes atteintes de démence) ont été les **moteurs** de cette thèse et donnent des indications sur notre **expérience acquise en thèse CIFRE** qui nous ont amenés à nos résultats.

2. Du latin *exempli grātia*, nous utiliserons la notation "e.g." pour signifier "par exemple" tout au long du manuscrit.

Première partie

Modèles pour la Détection de Comportements Multi-Agents

"It ain't what you don't know that gets you into trouble. It's what you know for sure that just ain't so."

Mark Twain

Introduction

La détection de comportements nous semble suivre le même processus décisionnel qu'effectue l'homme : son identification, son apprentissage et sa reconnaissance.

Les approches de simulation et de détection des comportements collectifs se basent sur les *théories sociologiques* de ce phénomène. Elles ont été adaptées par le domaine de l'intelligence artificielle (IA) sur les trois niveaux de modélisations que nous introduisons dans ce chapitre : *micro*, *méso* et *macro*. La détection repose sur deux parties complémentaires afin de modéliser des comportements : la fusion de données pour l'évaluation de la situation (chap.2), qui est la source des données d'observations permettant (chap.3) l'apprentissage et la reconnaissance des comportements collectifs (chap.1).

Les approches de *fusion de données* représentent cette première partie. Elles permettent d'obtenir des informations de haut niveau à propos des comportements par un processus complet : cela débute par l'*extraction des données* issues du signal des capteurs de surveillance, il s'en suit le pistage des multiples entités de la situation observée et se termine par l'évaluation de la situation (notamment celle nommée *asymétrique*³). À partir de ce résultat, les *comportements normaux* et *déviants* peuvent être identifiés sur les trois niveaux d'observations.

L'*apprentissage* et la *reconnaissance* des modèles de comportement sont la seconde partie du processus de détection. Un comportement peut être modélisé par apprentissage de manière à permettre sa reconnaissance quand il sera à nouveau observé. Pour modéliser des comportements, nos deux approches générales ont percé afin de réduire la complexité : ainsi la *décomposition séquentielle* et *hiérarchique* des comportements sont présentée.

3. Pour résumer, une situation asymétrique implique au moins deux camps de forces opposées et distinctes. Cette notion sera plus amplement décrite dans sa propre section.

Chapitre 1

Comportements Collectifs

Sommaire

1.1 Point de vue sociologique	14
1.1.1 Théories portant sur les comportements collectifs	14
A. Théorie de la contagion sociale	14
B. Théorie de la convergence sociale	16
C. Théorie des normes émergentes	16
D. Théorie de la valeur ajoutée	17
E. Foules et Mouvements Sociaux	18
1.1.2 Théories portant sur les groupes	18
A. Notion de proxémie	19
B. Caractéristiques d'un groupe	20
C. Primitives d'interactions locales de groupe	21
1.1.3 Appropriation par les approches d'intelligences artificielles	21
1.2 Micro vs Méso vs Macro : Trois niveaux de modélisations	23
1.2.1 Micro - Individus par des agents	24
1.2.2 Macro - Foule par un système multi-agents	25
A. Structure organisée	25
B. Stimuli communs d'une foule	26
1.2.3 Méso - Groupes par des systèmes bio-inspirés	28
A. Notion de flocking	28
B. Systèmes à base de phéromones	29
1.3 Conclusion	29

L'objectif de ce chapitre est d'obtenir une compréhension des comportements collectifs. Qu'ils soient émergents ou habituels, ils sont sous l'influence des liens sociologiques produits entre les individus rassemblés. Ces liens sont encore plus forts quand ces rassemblements sociaux deviennent hors de contrôle. Ainsi les comportements collectifs comportent des indices culturels qui vont nous permettre de les modéliser. Toute modélisation informatique d'un phénomène se base sur les théories développées par les experts du domaine. Dans notre cas, le phénomène en question est le comportement collectif et les experts appartiennent au domaine de la sociologie.

Dans la première section, nous présentons le point de vue sociologique portant sur ce phénomène. En commençant par les théories, nous allons présenter leur évolution produite durant ces deux derniers siècles face aux différentes formes de comportements collectifs qui ont été observées et/ou vécues. La section suivante présente les adaptations en IA selon trois niveaux d'observations fondamentaux : micro, méso et macro.

1.1 Point de vue sociologique

Pour modéliser les comportements collectifs, nous pouvons nous baser sur des théories sociologiques les décrivant. Cela est simple sur les théories d'avant l'époque postindustrielle, puisque les sociologues les décrivaient comme la manifestation d'un comportement de masse alimenté par des forces irrationnelles. Ce n'est plus le cas aujourd'hui. Depuis le siècle dernier, les gens ont pris l'habitude de se réunir pour différentes raisons socioculturelles. Au fur et à mesure de l'émergence des différents types de rassemblements sociaux, les sociologues développent leur propre interprétation des comportements collectifs. Toutefois, ils ont majoritairement reconnu leur capacité à changer les conditions sociales et à transformer les valeurs culturelles.

Les sous-sections suivantes nous décrivent l'évolution des théories portant sur les comportements collectifs et les groupes dont le résultat a été appliqué aux approches d'intelligences artificielles.

1.1.1 Théories portant sur les comportements collectifs

Les **comportements collectifs** sont des phénomènes d'auto-organisation des individus de cette foule. Ce sont des comportements émergents spontanés sans coordination concrète (planification ou règles) [Sumpter, 2006]. Les théories sociologiques à propos des comportements collectifs ont évolué du point de vue interne (en y participant) et/ou externe (en observant) à ce phénomène.

Sociologiquement, il y aurait deux formes de comportements collectifs, la foule et le mouvement social, qui ne sont pas à confondre. Un **comportement collectif** peut être décrit par les actions, les pensées et les sentiments d'un groupe (de personnes) provisoire et non structuré. En revanche, un **mouvement social** est un rassemblement de personnes suivant un comportement organisé conçu pour provoquer ou résister à un changement de la société.

A. Théorie de la contagion sociale

La première théorie sociologique du comportement de foule, maintes fois reprise, est la **théorie de la contagion sociale** (*social contagion theory*) :

- I. Sa première évocation se trouve dans le livre intitulé "*Psychologie des foules*" de [Le Bon, 1900] qui est devenu un classique de la littérature sociologique et dont les théories sont toujours valides aujourd'hui. Il suggère que la **foule** produit une pensée collective qui a une forte influence sur celle de chaque individu et les fait agir en conséquence. Certains facteurs faciliteraient l'émergence des émotions dans la foule :

- Les membres de la foule se sentent anonymes et se libèrent des contraintes habituelles, et cette rupture des normes est contagieuse ;

- Quand la foule atteint un niveau émotif critique, les membres perdent leur capacité à résister aux suggestions des membres influents, et toute réaction émotive forte est rapidement diffusée.

II. Pour [Park, 1904] dans "*The Crowd and the Public*", les comportements de foule ne sont pas dus à une "émotion irrationnelle contagieuse" (i.e. I. *Le Bon*). Le responsable serait une **anomie sociale** : dont la définition est la désintégration des normes qui régissent la conduite des hommes et assurent l'ordre social. Nous observons ce phénomène dans les situations qui vont de la période d'instabilité sociale à la notion de festivités. Ainsi selon la situation, les idées contagieuses produites incitent les personnes à devenir insensées et enclines aux réactions massives. Le processus d'**imitation de la collectivité** affaiblit le contrôle et le jugement individuel. En d'autres termes, la foule devient la **norme**, tout ce qu'elle représente est jugé juste et toute opposition est considérée comme mauvaise.

III. Son élève [Blumer, 1951] redéfinit les concepts de Park (i.e. II.) et considère que chaque personne agit selon son interprétation des mots et des actions des autres. Il identifie cinq étapes pour l'**émergence d'un comportement de foule** où chacune finit par entraîner la suivante :

- (i) un événement déclencheur produit la confusion et le manque de consensus,
- (ii) la panne des normes sociales produit un rassemblement spontané,
- (iii) le "*milling*" (i.e. évoque les mouvements circulaires des troupeaux sans but),
- (iv) la libération de l'excitation collective produit l'émergence d'un objectif commun,
- (v) et l'émergence d'un acte collectif final par la participation active et élémentaire de chaque individu.

Il définit ainsi le concept de la **masse** comme étant différent de la foule, où les individus d'une masse ont deux choses en commun : (1) les membres ne se connaissent pas, et (2) ils engagent des interactions que s'ils se ressemblent dans leurs sentiments et dans leurs actes. En raison de cette "séparation spatiale", ils ne peuvent ni s'organiser comme une foule ni éprouver le genre d'excitation collective qui mène à l'action collective immédiate. Au lieu de cela, les membres d'une masse développent une conscience de soi par rapport aux autres groupes. Cette conscience leur fait partager une attitude ou une activité commune. Tandis que leurs actions sont impulsives et peuvent même contredire leur bon sens habituel, ils s'unissent à d'autres du fait qu'ils se concentrent sur un objectif commun.

IV. [Turner and Killian, 1957, Killian and Turner, 1972], élèves de Blumer (i.e. III.), conceptualise la **norme émergente** : les interactions verbales et les diverses formes de communication et d'échange au sein du groupe permettraient une reconstruction sociale et morale de la situation, une définition partagée qui va justifier et coordonner l'action entreprise. Selon eux, les interactions de la foule produisent des normes en deux étapes, (1) quand les gens agissent les uns sur les autres, cela produit de nouvelles normes spécifiques à la foule et (2) la foule fait alors pression sur les membres qui ne sont pas conformes. De cette manière, des membres qui se sentent opprimés et souhaitent renverser leurs oppresseurs risquent d'employer la violence, ce qui transformerait la foule en émeute.

La limite de cette théorie concerne principalement sa **définition instable** dans le domaine de la sociologie. En effet, chaque auteur sociologue la redéfinit et l'utilise selon sa propre interprétation de la contagion sociale. Cette **interprétation** indique parfois une observation neutre lorsque l'auteur n'avait aucun intérêt (bon ou mauvais) selon l'objectif qui a amené à produire le rassemblement social, optimiste

lorsque l'auteur y avait un intérêt à y participer et pessimiste lorsque l'auteur en a subi les conséquences (notamment lors des événements de 1968).

Les trois théories suivantes nous permettent d'éclaircir le sujet.

B. Théorie de la convergence sociale

La seconde plus importante théorie est sans doute la **théorie de la convergence sociale** (*social convergence theory*). Elle reprend totalement la théorie de la contagion sociale (A. page 14), mais suggère que les membres de la foule agissent de manière inconsciente sans perdre leur individualité. [Kis, 1971] raconte l'évolution de cette théorie qui a pour origine le domaine de recherche de la biologie à propos de la *phénoménologie de convergence observable* de W. Stern (1935).

C. Théorie des normes émergentes

La **théorie des normes émergentes** [Killian and Turner, 1972] (*emergent-norm theory*) observe les foules comme des collectivités composées de personnes ayant des intérêts et des motivations mélangés. Particulièrement dans le cas de foule peu stable (i.e. expressive, agissante, protestante), ses normes peuvent être vagues et changeantes. Par exemple, une personne décide de casser les vitrines d'un magasin alors d'autres se joignent à elle et commencent à piller les marchandises. En d'autres termes, les membres des foules établissent leurs propres règles à partir des actes qui s'y produisent. Sur la base de ces arguments, un **comportement collectif** s'établit en quatre étapes :

1. La situation produit de l'incertitude et de la confusion. Le **comportement d'imitation** cherchera le besoin de spécificité, de certitude et de consensus par rapport à la situation.
2. Quand un membre débute une action, les autres membres attendent une réaction d'opposition à ce comportement. S'il n'y en a pas, alors ils concluent qu'il est acceptable. Ironiquement, c'est cette "normalisation" qui encourage et permet aux individus de s'engager dans un comportement rompant avec les normes.
3. Ainsi, certaines personnes chercheront à se conformer aux normes du groupe ou de la société, ils sont susceptibles d'accepter et de suivre une nouvelle norme émergente, spécialement quand il n'y a pas d'opposition ouverte.
4. Les gens s'engagent dans un nouveau comportement, non pas à cause de prédispositions irrationnelles, mais puisqu'il semble être la "bonne" action à mener.

Ce comportement d'imitation suit un **processus** précis pouvant être simulé.

Le second point important de la théorie [Killian and Turner, 1972] est la **catégorisation du comportement collectif** selon les motivations des participants :

- Les engagés (*committed*) sont alimentés par leur conviction émotionnelle que quelque chose doit être fait ; ils sont plus que prêts à assumer le rôle de leader.
- Les concernés (*concerned*) sont prêts à autant s'engager lorsqu'ils voient une action, mais seulement lorsque l'initiative a été prise par les autres.
- Les peu sûrs (*insecure*) sont intéressés dans la participation parce qu'ils ont un besoin d'appartenance ; à cause de ce besoin inné, ils agiront, quelle que soit la direction choisie par les leaders des groupes.

- Les spectateurs (*spectators*) sont soit curieux, soit sympathisants ; i.e. ils ne participent pas à l'action, mais ils peuvent encourager l'action.
- Les exploiteurs (*exploiters*) se joignent à une action collective, car ils ont besoin de libérer leurs propres contraintes comportementales ; ils cherchent les groupes sur le point d'éclater, espérant profiter de la vague de sentiments.

Chaque agent dans une foule simulée aura alors l'un de ses rôles à jouer.

D. Théorie de la valeur ajoutée

Cette théorie porte sur l'émergence des actions collectives et présente les conditions pour l'émergence d'un comportement collectif.

Le livre intitulé "*Theory of Collective Behavior*" de [Smelser, 1962] capitalise une grande quantité de ces recherches sociologiques sur les comportements collectifs (et a été publié à nouveau en 2011), notamment la **théorie de la valeur ajoutée** (*value-added theory* ou *social strain theory*) toujours utilisée aujourd'hui. Selon elle, six causes déterminantes sont nécessaires et suffisantes **pour qu'un mouvement social émerge** (i.e. une action collective pour changer une situation devenue insupportable) : voir le tableau 1.1.

(i) Un contexte problématique provoquant : (ii), (iii), (iv), (v) et (vi)	qui incluent des facteurs qui permettent la possibilité de certains comportements, notamment par la proximité sociale.
(ii) des tensions structurelles :	comme les tensions sociales (par les inégalités ou le sentiment d'injustice).
(iii) des croyances communes désignant la cause du problème :	où les participants au mouvement social doivent aboutir à une compréhension du problème en question.
(iv) des facteurs déclencheurs :	tel qu'un événement collectif qui confirme aux participants que leurs croyances communes sont rationnellement fondées.
(v) la mobilisation pour l'action :	nécessitant la mise en place d'un minimum d'organisation de la part des participants.
(vi) l'échec du contrôle social :	la manière dont les autorités réagissent (ce qui inclue aussi leur absence de réaction).

TABLEAU 1.1 – Les six causes déterminantes, nécessaires et suffisantes **pour qu'un mouvement social émerge** [Smelser, 1962].

En d'autres termes, lors de mouvements sociaux, les **comportements collectifs** aident la société puisque les actions collectives (menées à leurs termes) sont le moyen de diminuer la tension (accumulée par la société de manière périodique lors d'événements historiques contrôlables). Les comportements collectifs seraient déterminés par des facteurs sociaux plutôt que psychologiques.

Une caractéristique utile de cette théorie est le fait qu'un système de détection, lorsqu'il identifie ces causes, pourrait prévoir quand, où et pourquoi un épisode collectif va se produire. Elle permet d'analyser les niveaux de tension d'une société à un moment donné. Une telle information permet une prévention par la mise en place de mesures de contrôle.

E. Foules et Mouvements Sociaux

Les foules et les mouvements sociaux produisant des comportements collectifs ont des différences et similarités à présenter selon le type de situation et le niveau d'observation.

Quel que soit le **mouvement social**, plusieurs étapes le caractérisent :

1. À l'étape préliminaire, la société montre un souci, une agitation à propos d'une question sur laquelle les gens sont divisés.
2. À l'étape populaire, les mouvements commencent à se rassembler autour d'un leader charismatique qui parle pour la réforme, la révolution, la résistance ou l'expression de l'individu. Ceci de telle manière que les gens commencent à croire que leurs questions trouveront des réponses et ils s'en rapportent à lui.
3. Dans l'étape finale, le mouvement se détruit de lui-même et/ou devient une institution ayant des normes organisées et admises de la société.

Parmi les types de foules et de mouvements sociaux, quatre sont comparables et produisent chacun un type de comportement collectif :

- | | |
|--|---|
| 1. La foule <i>occasionnelle</i> est réunie pour un événement spécifique où les membres ont peu d'interaction entre eux. | 1. Les mouvements de <i>résistance</i> sont formés pour résister à un changement qui se produit déjà dans la société. |
| 2. La foule <i>conventionnelle</i> se réunit pour un objectif socialement autorisé. | 2. Les mouvements de <i>réforme</i> essaient de changer des éléments du système qui est en fonction. |
| 3. La foule <i>expressive</i> se réunit spécialement afin d'exprimer leurs émotions. | 3. Les mouvements <i>expressifs</i> se concentrent sur le changement parmi leurs membres et leurs interactions sociales immédiates. |
| 4. La foule <i>temporaire</i> se concentre sur une action ou un objectif spécifique à produire. | 4. Les mouvements de <i>révolution</i> nient que le système fonctionnera toujours et cherchent à le remplacer. |

En définitive, la prise de décision individuelle joue un rôle important dans un comportement de foule. En effet, ce processus décisionnel s'y adapte, de manière plus ou moins importante, selon le rôle de l'exécuter (et son poids social dans la société), des observateurs (leaders, disciples, spectateurs inactifs, opposants,...) et selon l'importance des actes générés par la décision.

Les théories sociologiques que nous venons de voir nous montrent un aperçu des comportements collectifs lors de rassemblements sociaux composés de multiples groupes d'individus. La question est de savoir dans quelle mesure ces théories s'appliquent également aux groupes (mis à part le niveau différent d'observation et donc de modélisation).

1.1.2 Théories portant sur les groupes

Pour statuer qu'un ensemble d'individus forme un groupe, les théories sociologiques se basent au niveau micro sur leurs proximités physiques, leurs mouvements corrélés, leurs caractéristiques communes et leurs primitives d'interactions locales.

A. Notion de proxémie

La question la plus complexe ici est d'identifier à partir de quand un ensemble d'individus forme un groupe. Les membres d'un groupe auraient une relation sociale qui peut s'estimer par la distance physique et temporelle entre ces individus. Ce concept se nomme la **proxémie** et :

- est un terme d'anthropologie introduit par [Hall, 1974] ;
- porte sur la distance physique qui s'établit entre des personnes prises dans une interaction ;
- propose des limites (observables dans la Figure 1.1) qui séparent l'espace intime, personnel, social et public des gens ;
- reconnais qu'elles varient selon les cultures et les lieux d'interactions.




FIGURE 1.1 – Diagramme des sphères proxémiques dans les pays occidentaux (Source : http://commons.wikimedia.org/wiki/File:Personal_Space.svg)

Nous pourrions utiliser ces limites comme des seuils, qui lorsqu'ils sont dépassés, nous indiquent des mouvements de groupes, allant d'un individu suivant un groupe jusqu'à l'émergence de groupes par la fusion (e.g. le mouvement corrélé de deux entités d'une ou plusieurs personnes) ou la fission (e.g. une séparation en sous-groupes). Nous pouvons comprendre que les membres d'un groupe, par leur proximité continue, ont des interactions structurées et attendues sur le comportement de chacun.

Toutefois, la proxémie doit prendre en compte deux notions importantes : l'historique et l'orientation des déplacements. Si nous ne les prenons pas en compte dans une tentative d'identification des groupes, alors les deux erreurs suivantes risquent de se produire : deux groupes se croisant seront considérés en

train de se rejoindre, et un groupe se séparant en deux pour éviter un obstacle sera considéré comme en train de se séparer.

Il est nécessaire de connaître les spécificités des groupes pour pouvoir les **différencier** et les modéliser.

B. Caractéristiques d'un groupe

Chaque groupe⁴ peut se différencier par sa structure, son meneur, son opinion et la manière d'y être intégré :

- i) La nature de la **structure** d'un groupe dépend souvent de la personne centrale (tel qu'un meneur). Un nouveau groupe est caractérisé par des désaccords et des conflits internes à propos de sa structure. Ensuite, il développe des structures formelles de plus en plus élaborées. Cette structure peut être formalisée par le fait qu'elle est, selon les besoins des membres de groupe, soit public et explicite (e.g. un parti politique), soit informel (privé) et implicite (e.g. une famille).
- ii) Les membres qui ont le plus haut taux de participation au groupe sont le plus souvent choisis pour être les **meneurs** du groupe (*leaders*). D'autres traits sont associés avec la qualité d'un dirigeant (le *leadership*) : l'intelligence, l'enthousiasme, la domination, la confiance en soi et l'égalitarisme (i.e. l'inverse de l'élitisme).
- iii) Les groupes récompensent généralement les membres qui respectent les normes. Ainsi le comportement individuel et le jugement envers chaque membre sont fortement influencés par l'**opinion** du groupe. Sous l'opinion de groupe, le manque de confiance en soi cause une pression amenant l'individu à se conformer au groupe. Cette désindividualisation se produit quand une personne est immergée dans un grand groupe qui a un fort sentiment d'unité (surtout lorsque le groupe se concentre sur des objectifs externes).
- iv) La **décision** de groupe a tendance à produire une décision plus performante que celle d'une seule personne, mais est beaucoup plus lente. Les membres sont parfois prêts à prendre des décisions impliquant un risque plus élevé que lorsque l'un d'eux serait seul à décider. Les groupes vont d'abord se concerter, pour évaluer les réactions négatives et positives à chaque propos, puis chercher à atteindre une prise de décision solidaire. Dans les cas où il y a de fortes différences d'opinions à propos de la décision à prendre, les groupes créent une situation dans laquelle les alternatives ne sont pas considérées de façon réaliste. Cela peut être combattu par le leader en étant à l'écoute des opinions de tout le monde, en demandant des conseils à l'extérieur sur la question et en affectant des membres sur chaque option proposée qui serait troublante.
- v) Un groupe ayant une organisation formelle s'est construit délibérément pour atteindre des objectifs spécifiques au travers de rôles clairement définis et de règles précises. Nous pouvons relever que les sociétés modernes sont caractérisées par la croissance de ces organisations et par la réduction des groupes premièrement créés.

Ainsi, un **groupe**, lorsqu'il n'est pas en mouvement, peut être modélisé par :

- un petit nombre de gens qui sont rassemblés,
- dont les membres ont des interactions de type face à face de manière plus ou moins régulière,
- qui possède un objectif et/ou une identité commune,
- et partagent un ensemble de normes régissant leurs activités.

4. Source : www.sociologyguide.com/questions/group.php

Après cette description sur les caractéristiques des groupes, il nous reste à savoir comment déterminer le **dynamisme** d'un groupe (i.e. les types d'interactions qui sont rencontrés par les membres d'un groupe).

C. Primitives d'interactions locales de groupe

Dans une situation dynamique, il est courant que les membres des groupes se regroupent, se décomposent, s'évitent,... [Mataric, 1993] définit 5 primitives d'**interactions** locales (i.e. Figures 1.2(a), (b), (c), (d), et (e) page 22) qui peuvent se combiner en 3 nouvelles interactions (1.2(f), (g) et (h)).

Dans la nature, la variabilité des individus génère des comportements robustes et adaptatifs. Leurs interactions primitives sont généralement décrites comme une variété de variations sensorielles et mécaniques. Combiner spatialement de telles interactions est un réel challenge, d'autant plus que les comportements d'un groupe peuvent se superposer dans le temps et dans l'espace (e.g. par des sous-groupes temporaires). De par les simples faits que nous venons de décrire (la proxémie, les caractéristiques et les interactions locales d'un groupe), il est possible de les modéliser et les reproduire par une intelligence artificielle.

1.1.3 Appropriation par les approches d'intelligences artificielles

L'un des objectifs du domaine de recherche de l'IA est d'effectuer une modélisation efficace en termes de rapidité d'exécution et de complexité. En l'appliquant aux comportements collectifs, celle-ci doit donc prendre en compte les différents aspects (notamment les imperfections et les incertitudes) de chaque comportement humain (e.g. du compréhensible à l'irrationnel).

Cinq axes de recherche [Cao et al., 1997] peuvent faire varier les possibilités et les limites d'un modèle de comportement collectif : (*Comme premier exemple, les termes suivants soulignés s'utilisent pour générer une foule en panique* [Patric et al., 2011]).

1. L'**architecture de groupe** qui comporte plusieurs paramètres à choisir :
 - La **centralisation** (où les agents sont contrôlés par un système hiérarchique) ou la **décentralisation** (où les agents sont contrôlés par un système distribué).
 - La **différentiation** : étant la manière de considérer les agents comme homogène ou hétérogène, tels que selon leurs états, actions et/ou objectifs.
 - La **structure des communications** dont les interactions peuvent s'effectuer via : l'environnement, les sens ou les communications.
 - La **modélisation des autres agents** : leurs états, intentions, croyances, capacités et actions possibles pour une meilleure coopération / coordination.
2. Les **conflits de ressources** qui apparaissent lorsqu'un ensemble d'agents se partage le même espace, les mêmes objets et les mêmes communications. S'il n'y a pas de règles établies, alors il y a risque de collisions.
3. La **manière de coopérer** qui détermine si les agents auront un comportement collectif antisocial ou coopératif.

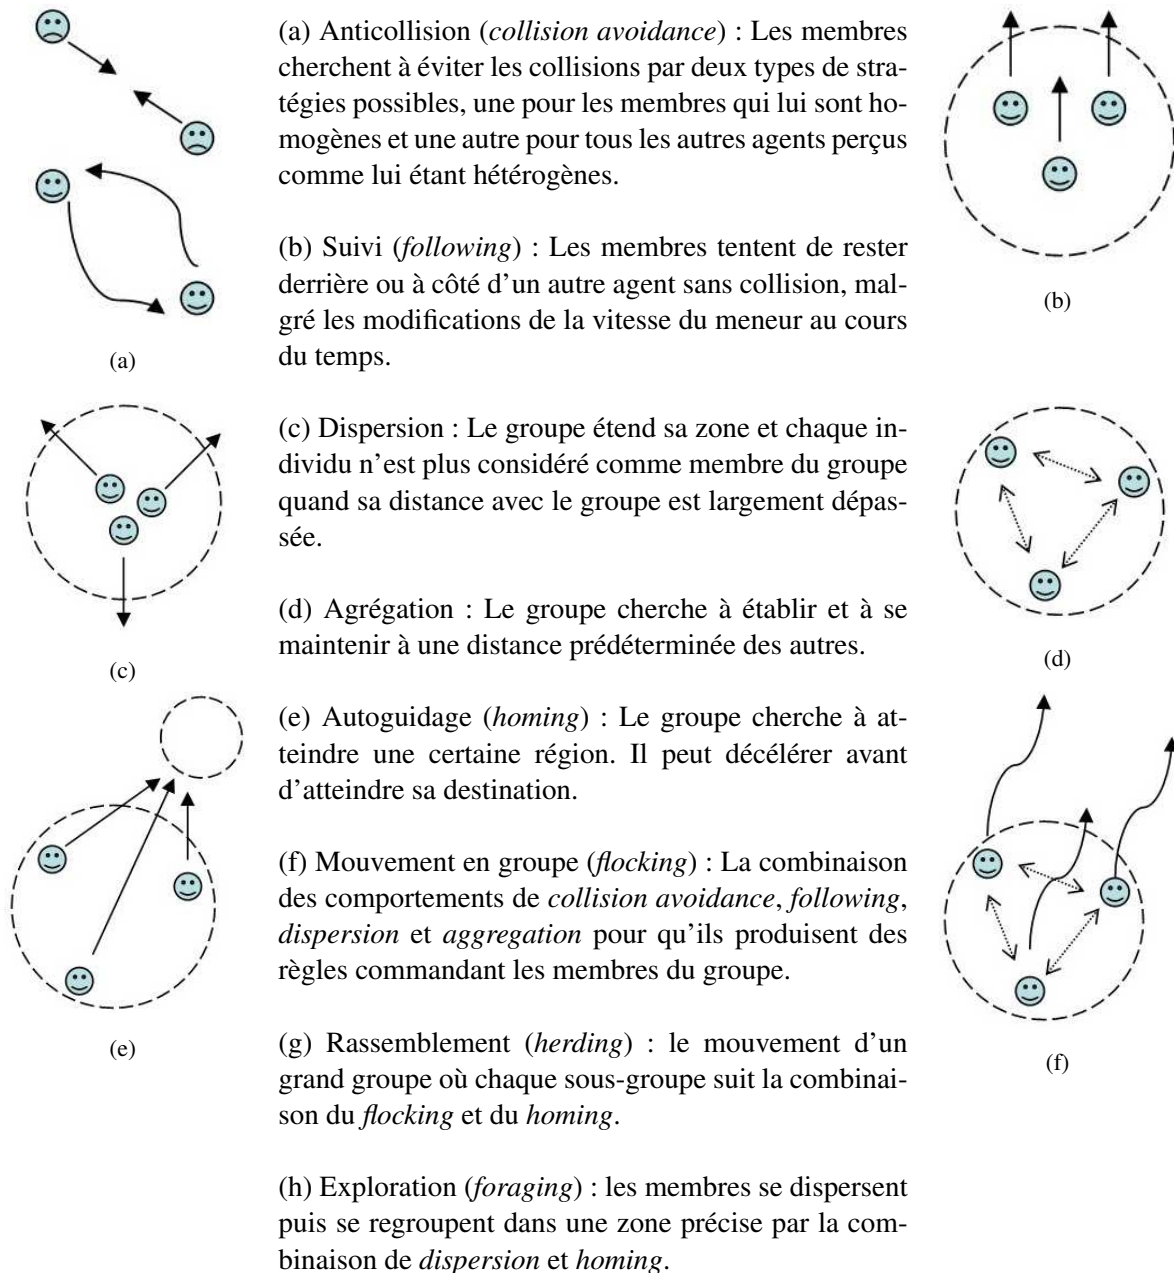


FIGURE 1.2 – Les primitives d'interactions locales parmi les comportements internes aux groupes.

4. L'**apprentissage** (par renforcement) qui contrôle les valeurs de paramètres des agents pour optimiser la performance et s'adapter aux changements.
5. Les **problèmes géométriques** pour prendre en compte l'environnement qui entoure les agents (par leurs perceptions incomplètes, les contraintes physiques et les possibles interactions).

Pour choisir les paramètres afin d'obtenir le meilleur modèle, la première lacune est notre difficulté à mesurer ses performances. Dans notre cas d'étude, le modèle se doit de reproduire les imperfections / incertitudes du comportement humain.

Comme second exemple, l'approche du **système complexe adaptatif** peut être définie [Van Ginneken and Van Ginneken, 2003] selon deux points de vue que sont (a) la théorie sociologique et (b) l'IA appliqué :

- (a) La **théorie des systèmes complexes adaptatifs** (*complex adaptive systems theory*) propose que la contagion, la convergence et les normes émergentes soient juste des exemples de la synergie⁵, de l'émergence et de l'autopoïèse⁶ ou l'autocréation.
- (b) Un **système complexe adaptatif** (CAS) se définit comme un ensemble complexe d'agents similaire, s'adaptant et interagissant. Les individus d'un comportement collectif auraient les mêmes macropropriétés que les CAS : l'autosimilarité, la complexité, l'émergence, l'auto-organisation. Un CAS est un cas particulier des **systèmes multi-agents** (MAS) puisqu'à la différence des MAS, un CAS comporte un haut niveau de capacité d'adaptation face aux perturbations dans son environnement.

Les théories sociologiques, produites pendant le siècle dernier, ont toujours influencé le développement des approches pour la modélisation des comportements collectifs. Ces dernières décennies, la tendance a commencé à s'inverser. Nous retrouvons de plus en plus de termes issus de l'IA dans la sociologie. En effet dans ce domaine, les avancées ont quelque peu changé la donne et c'est le propos de la section suivante.

La modélisation de l'envergure totale du comportement (collectif) humain se nomme le modèle **IOS** (*individual, organisationnal, society*) [Zacharias et al., 2008]. Il inclut les personnes, les équipes, les petits et grands groupes (comportant les différentes cultures, ethnies, religions,...), les sociétés, les nations et les coalitions nationaux. Ce dernier exemple nous démontre que nous devons définir les différents niveaux d'observations des comportements collectifs. Trois niveaux d'observations des comportements collectifs les représentent, que ce soit pour leur simulation et leur détection, qui sont les deux principaux objectifs de la modélisation en IA.

1.2 Micro vs Méso vs Macro : Trois niveaux de modélisations

Pour nous aider à comprendre les niveaux existants de modélisations, l'illustration de la Figure 1.3 représente la simulation 3D d'une foule dans une zone urbaine. Les événements observés peuvent être différenciés sur trois niveaux : (1) certains "individus" s'enfuient ou observent ceux en panique, (2) des "groupes" courent ou marchent et (3) la "foule" fait face à un phénomène de panique collective. Dans la littérature scientifique, trois approches de modélisation comportementales se distinguent [Zacharias et al., 2008] par le **niveau des modèles formels** :

- i. **macro** signifiant les modèles de comportements de sociétés,
- ii. **méso** incluant les comportements de groupe,
- iii. et **micro** indiquant les comportements individuels.

Dans chacune des trois sous-sections suivantes, ces trois niveaux d'observations sont définis en s'appuyant sur la sociologie et l'IA.

5. Il y a **synergie** quand les effets d'une action sont supérieurs à ceux prévus lorsqu'ils sont produits par plusieurs éléments agissant de concert.

6. L'**autopoïèse** est la capacité de se maintenir soi-même malgré l'interaction avec l'environnement et ses changements

FIGURE 1.3 – Une situation simulée est observable sur trois niveaux de modélisation : macro pour la foule, méso pour les groupes et micro pour les individus.



(a) Les points bleus représentent les mêmes individus classifiés par un cercle orange selon les trois niveaux d'observations.

(b) Malgré une observation de ce scénario au-dessus de la foule, il n'est pas aisé de distinguer les trois niveaux d'observation des comportements collectifs. Au niveau macro, il y a des mouvements orientés dans les deux sens de la rue. Au niveau méso, nous pouvons observer des groupes (par la proxémie) en fuite sur la gauche et en train de marcher calmement sur la droite. Au niveau micro, en ayant distingué les comportements collectifs, deux à trois individus se distinguent par leurs différences de mouvements et de distances aux autres.

1.2.1 Micro - Individus par des agents

Le niveau micro est le plus bas niveau de modélisation et s'intéresse au rôle d'un individu parmi la foule. De par ce fait, chacun possède sa propre architecture logicielle basée sur un modèle de cognition humaine. Différentes architectures englobent les aspects distincts de la cognition humaine : la mémoire, le multitâche, l'attention, l'apprentissage,... Dans le domaine de l'IA, une telle architecture cognitive est représentée par un agent.

Selon les définitions de [Ferber, 1995, Russell and Norvig, 2003, Wooldridge, 2002], les *agents* sont dotés de capacités de perception de leur environnement (notamment concernant les autres agents), de moyens d'action (comportement individuel) et de règles de décision, permettant de choisir certains aspects de leur comportement présent en fonction des variables internes et externes qui leur sont accessibles.

Pour un ensemble d'agents non coopératifs, chaque agent a un objectif individuel et peut interagir avec d'autres agents pour accomplir son objectif. Dans cet exemple (Figure 1.3) où les gens sont en panique, l'objectif est le même pour tous, s'échapper (quand ils se rendent compte de la présence d'une menace), mais chacun essaye d'accomplir le sien en priorité sur celui des autres. Cet objectif simulé est simplifié par rapport à la réalité. Un individu dans une foule en panique aura tendance à faire confiance à une autorité supérieure comme un groupe et le suivre. Nous retrouvons ce concept dans

[Fiske, 1993, Fiske, 2000], où est proposé un modèle conceptuel de l'humain par la **théorie des modèles relationnels**. Cette théorie suppose que les gens utilisent quatre paramètres élémentaires pour produire, interpréter, coordonner, contester, planifier, se souvenir, évaluer et réfléchir à propos de la plupart des aspects des interactions dans toutes les sociétés : le partage communautaire, les rapports hiérarchiques, les relations d'échanges réciproques et les relations instrumentales. Ces quatre paramètres sont organisés en un ensemble de concepts et de règles associés qui sont utilisés comme une grammaire générative pour réfléchir et coordonner les relations sociales quotidiennes.

Afin de simuler un comportement de foule par un modèle formel d'individu au niveau micro, l'architecture cognitive de chaque agent doit permettre qu'il calcule lui-même ses intentions en fonction de ses désirs et ses croyances à propos de son environnement. Ce type de modèle d'agent est inclus dans l'**architecture BDI (Belief, Desire and Intention)** [Bratman et al., 1998, Rao and Georgeff, 1997] pour générer des comportements hybrides :

- ▷ **Réactif** pour la planification d'une décision la plus rapide : ce qui correspond aux comportements réflexes dans une situation à haut risque, dans lequel un individu produit directement en réponse de stimuli en temps réel ;
- ▷ **Cognitif** pour suivre un plan à long terme.

L'idée générale est que chaque agent varie entre ces deux types de comportements selon ses besoins immédiats, tout comme un humain le ferait.

En utilisant une architecture BDI, un nouveau problème apparaît : le besoin en temps et en ressources de calcul augmente avec le nombre d'agents. Les systèmes multi-agents basés sur les approches bio-inspirées proposent de résoudre ce problème et permettent l'émergence de comportements collectifs.

La simulation d'une foule requiert donc un agent pour chaque individu. Le nombre d'individus simulés se retrouve ainsi limité par la puissance requise pour les calculs et non par la difficulté de les modéliser.

1.2.2 Macro - Foule par un système multi-agents

La formalisation de modèle au **niveau macro** [Zacharias et al., 2008] représente le comportement d'humains dans un groupe ou une organisation. Le modèle est hiérarchisé pour chercher à expliciter les relations et à prédire l'évolution face à une modification des conditions, en se plaçant dans une perspective d'équilibre général. Le modèle d'un système dynamique (macro) est une méthode modélisant le comportement dynamique des systèmes complexes par la décomposition de ces systèmes en simples composants ("blocs") interconnectés ensemble (des sorties aux entrées des blocs).

Pour tenter de pallier la complexité des systèmes multi-agents, les approches proposent une structure organisée.

A. Structure organisée

[Durfee et al., 1987, Horling and Lesser, 2005] ont prouvé l'importance d'une structure organisée afin d'améliorer l'efficacité d'un système multi-agents. La Figure 1.4 nous présente un exemple de structure organisée de manière efficace : chaque agent va interagir seulement avec ses voisins locaux (i.e. leurs zones de perceptions et d'influences se croisent). Dans notre cas d'étude, la structure doit être organisée

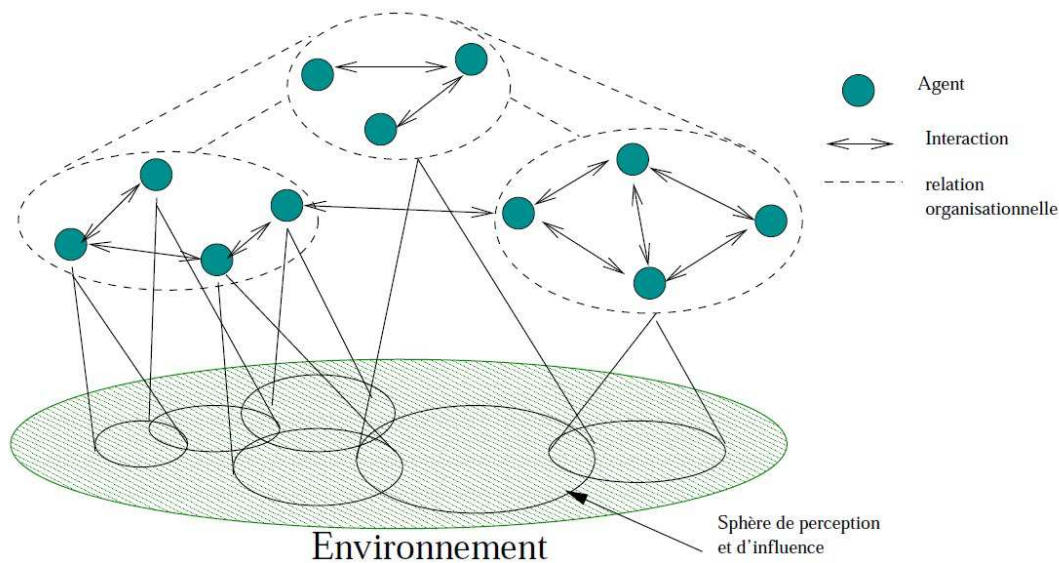


FIGURE 1.4 – Une structure de système multi-agents [Boussard, 2008]

pour les comportements de foule [Fridman and Kaminka, 2007], ce qui inclut deux caractéristiques additionnelles : le stimulus commun entre les participants de la foule et la capacité d'imitation des autres participants. Le *modèle* [Helbing et al., 2000] reproduit ces caractéristiques d'**imitation** et de **contagion** parmi la foule.

B. Stimuli communs d'une foule

Le comportement de foule réagit notamment à des stimuli communs comme : la stigmergie, la capacité d'imitation et de contagion.

En considérant un simulateur de foule, les agents doivent fonctionner en stigmergie [Beckers et al., 1994, Cao et al., 1997, Grasse, 1959]. Leur définition de la **stigmergie** peut être traduite par "*la production d'un certain comportement par les agents comme étant la conséquence des effets produits dans l'environnement local par les actions précédentes*". Le choix de la modélisation dépend donc de la nature du problème à résoudre. En ce sens, un cas de foule en panique concerne les modèles micro afin de représenter les comportements individuels en cas de panique.

La capacité d'imitation et de contagion se retrouve dans le modèle d'[Helbing et al., 2000]. Il permet "*une mixture de forces socio-psychologiques et physiques influençant le comportement dans une foule : les agents préféreront se déplacer avec une certaine vitesse désirée dans une certaine direction, et alors chercheront à adapter leur vélocité actuelle en un temps minimal*". Simultanément, un agent essaiera de garder une vélocité dépendante des distances avec les autres agents et obstacles. Ceci peut être modélisé par des forces d'interactions selon les agents et obstacles proches. La tendance psychologique, de deux agents à rester à une distance minimale des autres, est décrite par une force d'interaction répulsive. Quand un agent touche un autre ou un obstacle, deux forces additionnelles inspirées par les interactions granulaires sont essentielles pour comprendre les effets particuliers produits dans les foules en panique :

une force de compression des corps par contact et une force de friction empêchant un mouvement relatif tangentiel.

Les équations présentées dans [Helbing et al., 2000] nous permettent de reproduire la même expérience (Figure 1.5) pour un simulateur de foule en utilisant les paramètres suivants :

- une masse de 80 kg (en moyenne) variant uniformément pour chaque agent corrélé à un diamètre (i.e. le tour de taille) variant de l'intervalle 0.5 m à 0.7 m ;
- un temps de 0.5 s pour répercuter une accélération ou une décélération qui amène l'agent à sa nouvelle vitesse ;
- une vitesse supérieure à 5 m/s (jusqu'à 10 m/s) : spécifiquement, les vitesses observées pour quitter une pièce correspondent à 0.6 m/s en condition relaxée, 1 m/s en condition normale, et au maximum 1.5 m/s en condition nerveuse ;
- une distance gardée par rapport aux autres individus pendant une marche à vitesse normale et pendant le passage d'un goulot d'étranglement : les effets d'obstructions dans le cas d'interactions physiques quand les agents sont en train de passer une porte d'un mètre de large produisent un taux de 0.73 agents/s avec une vitesse de 0.8 m/s.




FIGURE 1.5 – Le modèle d'Helbing appliqué (extrait de [Helbing et al., 2000]).

Ce modèle est utile pour calculer la direction réelle de chaque agent selon celle qu'il désire, ainsi que les interactions physiques entre les agents et les obstacles. En se basant dessus, il est possible de calculer les résultats de bousculades et piétinements simulés durant les mouvements de panique. Sa principale lacune est l'absence d'hétérogénéité parmi les agents puisque tous les agents sont homogènes. Dans la "réalité" en cas de panique, les comportements collectifs ne sont pas produits de la même manière parmi la foule.

Pour y remédier, la solution peut être complétée par le modèle **SCT** (*social comparison theory*) [Fridman and Kaminka, 2007] qui génère la même capacité d'imitation et de contagion de la foule. Basé sur la **théorie des comparaisons sociales** [Festinger, 1954], le modèle fonctionne sur le fait que quand un agent ne connaît pas son état, alors il aura tendance à se comparer aux autres agents qui lui sont proches et il tentera de corriger les différences trouvées. Pour illustrer notre propos, la Figure 1.6 présente le processus SCT en trois étapes (en ligne) dans deux différents environnements (en colonne). Il y a deux types d'agents (gris et noirs) et leurs directions sont indiquées par la flèche qui les positionne. La colonne de gauche montre que la foule se sépare en groupes d'agents du même type. Celle de droite nous montre la séparation en deux files (une par type d'agents) à la rencontre d'un obstacle.

Quel que soit le modèle de comportement de foule, le point noir reste l'absence de décision à propos de la direction choisie par chaque agent à chaque pas de temps. L'avantage des SMA permet d'en modéliser et de simuler un grand nombre d'agents. Toutefois, une limite apparaît, qui se réfère à un problème connu dans les méthodes quantitatives de modélisation, qui est la **généralisation excessive** (*overgene-*




FIGURE 1.6 – Le modèle SCT appliqué (extrait de [Fridman and Kaminka, 2007]).

ralization) : une simulation de foule (au niveau macro) va produire des groupes uniformes (au niveau méso) ce qui ne représente pas la réalité. Il y a alors une perte de l'individualisation des groupes, ce qui entraîne la disparition de l'émergence (normale) de différents types de comportements collectifs parmi la foule.

1.2.3 Méso - Groupes par des systèmes bio-inspirés

Pour palier la **généralisation excessive** (*overgeneralization*) des approches macro et le **surapprentissage** (*overfitting*) des approches micro, le niveau intermédiaire **méso** de modélisation permet la modélisation des comportements de groupes. Pour garder une faible complexité, les approches se sont inspirées des animaux vivants en collectivité.

Une source d'inspiration pour la création de SMA est le comportement collectif animal intelligent qui a permis de produire les **systèmes bio-inspirés**. Il s'agit de la simulation de simples organismes qui produisent collectivement des comportements émergents à partir d'interactions simples.

Si nous recherchons le moyen de simuler simplement une foule en panique, les deux approches bio-inspirées suivantes sont à étudier pour l'émergence de leur comportement collectif.

A. Notion de flocking

L'intelligence collective naturelle s'observe principalement chez les insectes sociaux (fourmis, termites, abeilles), chez les animaux se déplaçant en formation (oiseaux, poissons), chez les mammifères sociaux chassant en meute (loups, hyènes, lionnes) et d'autres, encore moins connus (araignées, écureuils). En s'inspirant de ces animaux, des propriétés spécifiques peuvent être ajoutées aux agents qui les exploiteront. Des points communs caractérisent ces intelligences collectives naturelles :

- les individus aiment la proximité de leurs semblables et tendent à être grégaires (i.e. à se regrouper en une communauté structurée) ;
- ils interagissent de manière locale par le moyen de signaux (e.g. grognements, phéromones, attitudes) ;
- l'individu seul répond instinctivement à certains stimuli et la coordination du groupe se fait au travers de règles comportementales très simples au niveau individuel.

Introduit dans [Reynolds, 1987], le *flocking* est similaire aux déplacements d'un groupe d'oiseaux. Dans une telle organisation, chaque comportement d'agent est autonome et basé sur ses propres observations locales. Le modèle de base consiste dans les règles suivantes (Figure 1.7) :

- ◇ *Séparation* : les agents cherchent à ne pas être trop proches les uns des autres ;
- ◇ *Alignement* : les agents cherchent à s'aligner avec la direction globale de leur voisinage ;
- ◇ *Cohésion* : les agents cherchent à ne pas trop s'éloigner les uns des autres.

Ces trois règles coordonnent localement les agents dans l'environnement (i.e. tout comme dans les "Primitives d'interactions locales de groupe" page 21). Nous obtenons une approche décentralisée, qui rend possible la simulation d'un très grand nombre d'agents en temps réel.

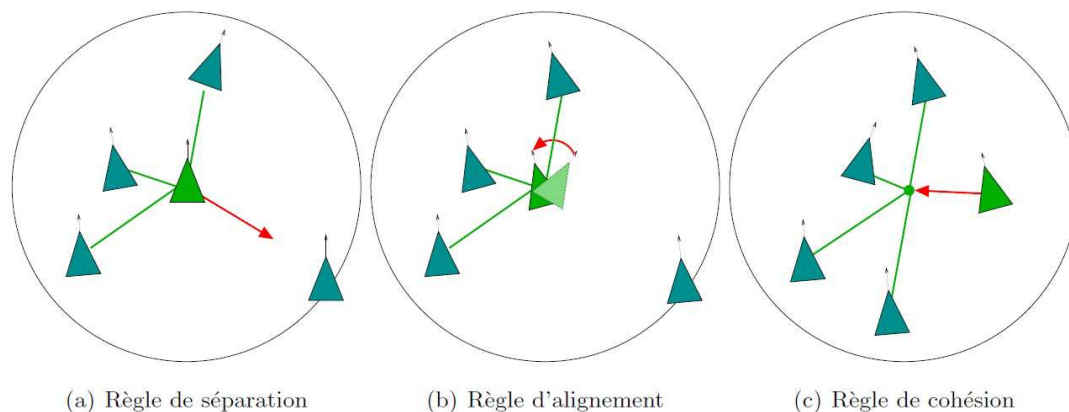


FIGURE 1.7 – Les règles du flocking [Boussard, 2008]

B. Systèmes à base de phéromones

Dans les *systèmes à base de phéromones*, inspirés par la manière dont les fourmis s'organisent collectivement, les agents sont fortement connectés avec l'environnement. Elles communiquent seulement de manière indirecte par le dépôt de phéromones sur l'environnement. Ainsi, un agent peut obtenir une mémoire simple des zones déjà perçues et visitées [Poisvert et al., 2010], lorsque les phéromones sont déposées avec une évaporation et une dispersion quasi inexistantes. Dans ce cas, les agents préféreront un chemin dans une zone avec le moins de phéromones afin d'éviter les zones déjà visitées, ceci tant qu'ils ne sont pas dans l'incapacité de se mouvoir. En utilisant cette simple propriété dans un cas de foule en panique, les agents continueront leurs mouvements (tout comme un individu paniqué s'enfuyant dans une direction constante). Ils éviteront de revenir sur leurs pas sauf s'ils se retrouvent bloqués.

1.3 Conclusion

Le point de vue sociologique exprimé dans ce premier chapitre nous a permis de comprendre plusieurs formes d'interprétation des comportements collectifs. Ces théories ont évolué au fur et à mesure de l'apparition de nouveaux comportements collectifs dans notre société depuis le dernier siècle. En premier lieu, le domaine de l'IA a modélisé ces théories. Aujourd'hui, l'évolution des approches de modélisation des comportements collectifs est telle qu'elles sont utilisées pour mettre à jour ces théories.

Les comportements collectifs peuvent être modélisés sur plusieurs niveaux d'observations et d'interactions : micro (les individus), méso (les groupes) et macro (la foule). Toutefois, il est plus judicieux de les modéliser selon le point recherché : le niveau micro permet une grande variété de comportement collectif émergent, mais réduit le nombre d'agents (par l'augmentation des calculs), le niveau macro permet une grande quantité d'agents, mais réduit le nombre de comportements collectifs émergents, le niveau méso semble un compromis entre les deux niveaux. Comme cela, les chapitres suivants se focaliseront à la détection de ces comportements collectifs sur ces mêmes niveaux.

Chapitre 2

Évaluation de la Situation par la Fusion de Données

Sommaire

2.1	Évaluation de situation asymétrique	32
2.1.1	Situations asymétriques	32
A.	Contexte de l'asymétrie	32
B.	Comportements récurrents dans les environnements asymétriques	33
C.	Formalisme d'une situation évaluée	34
2.1.2	Origine de la fusion de données	36
A.	Sources des données : des capteurs de surveillance	37
B.	Modèle JDL de fusion de données	38
2.2	Identification des groupes et des comportements déviants	41
2.2.1	Suivi de multiple personnes	41
A.	Pistage de groupe	42
B.	Reconnaissance d'équipe	44
C.	Centroïde, une modélisation de groupe	47
2.2.2	Comportements déviants (anormaux, inattendus et suspicieux)	48
2.2.3	Traitement des événements complexes	49
2.3	Conclusion	52

Pour la détection de comportements collectifs, la fusion de données est indispensable pour obtenir une évaluation de la situation (notamment dans le cas asymétrique qui sera défini dans la 1^{ère} section de ce chapitre). Cette évaluation de la situation se base sur un système de surveillance multi-capteurs. Leurs données sont fusionnées en plusieurs étapes de traitement de l'information. Ces étapes nous permettront, comme présentées dans la 2^{ème} section, d'identifier les (groupes d') entités de la situation surveillée et de vérifier si leur comportement est normal ou déviant, ceci sur chacun des niveaux d'observations (micro, méso, macro).

2.1 Évaluation de situation asymétrique

Dans une situation surveillée, les entités peuvent être suivies par des **capteurs**. En travaillant sur les signaux issus de ces capteurs, les approches de **fusion de données** nous proposent un traitement dont l'objectif est d'extraire les variables à propos de ces entités. Ces **observations** sont réutilisables pour l'identification des **relations** entre les entités elles-mêmes et à l'environnement. Ces résultats permettent d'obtenir une **évaluation de la situation** des entités présentes. Notre cas d'étude porte essentiellement sur les **environnements asymétriques** que nous définirons.

2.1.1 Situations asymétriques

Les comportements collectifs des situations asymétriques sont un contexte problématique connu des forces de sécurité. Afin de les aider face à ce problème, les définitions et les théories sur l'évaluation de situation dans les environnements asymétriques ont été ajustées.

A. Contexte de l'asymétrie

Afin de comprendre les termes liés à l'asymétrie, nous présentons sa définition. "*L'asymétrie caractérise le déséquilibre entre deux camps, celui qui conteste un état qu'il considère opposé à ses objectifs et celui qui prône la restauration d'un ordre propice à ses intérêts ; elle détermine également la diversité des modes de confrontation et des moyens mis en œuvre*" (Capitaine de Vaisseau de Rostolan⁷, membre du Club Hadrien).

Dans ces situations, ceux qui y participent sont des **acteurs asymétriques**. Selon [Clément-Noguier, 2003]⁸, ils disposent de moyens disproportionnés et d'objectifs militaires et politiques divergents. Ils recherchent l'avantage stratégique pour parer à leurs propres faiblesses, contourner la supériorité technologique et politique de leur adversaire, et accroître ainsi sa vulnérabilité, en utilisant des moyens alternatifs. La guerre asymétrique marque ainsi la fin de la guerre dite classique, fondée sur l'équilibre des forces entre deux pôles et la dissuasion nucléaire. Souvent appelée l'"arme du faible", l'asymétrie permet d'obtenir des résultats disproportionnés par rapport aux moyens utilisés, généralement très limités. Dès lors, les postulats traditionnels en matière de sécurité sont totalement bouleversés, à tel point qu'il nous est permis de considérer que l'asymétrie a pour effet de renforcer un sentiment général d'insécurité, lui-même disproportionné".

Un **environnement asymétrique** peut se définir comme l'ensemble des conditions naturelles (physiques) et culturelles (sociologiques) susceptibles d'agir sur les activités humaines qui sont présentes en au moins deux camps distincts et opposés. Nous avons produit cette définition en nous inspirant de trois types de pensées :

- ◇ La pensée chinoise contemporaine [Liang and Xiangsui, 1999] le définit comme étant le refus de se confronter à la force principale de l'adversaire et la recherche des points faibles à frapper qui entraîneront le plus grand choc psychologique à l'adversaire.

7. Source : <http://www.frstrategie.org/> (google webcache)

8. Source : www.cairn.info/revue-internationale-et-strategique-2003-3-page-89.htm

- ◇ La pensée américaine [Herman, 1997], quant à elle, le définit comme l'effet levier sur l'équilibre offensif / défensif à l'avantage du malfaiteur qui exploitera les vulnérabilités de la défense ou les contraintes de l'attaque avec des méthodes peu onéreuses et non conventionnelles. En effet, une attaque asymétrique est beaucoup moins onéreuse que de se défendre contre, et réciproquement face à une tactique défensive asymétrique.
- ◇ La pensée européenne le définit comme une étude des situations qui inclut la présence d'au moins deux forces armées humaines organisées ou non et de classes différentes (tel que l'appui ou l'absence de matériel et de logistique). Le concept de guerre asymétrique fut utilisé lors d'interventions de l'OTAN, mais a pour origine le livre *L'art de la guerre* [Tzu, 1997] (au 5^{ème} siècle avant J.-C).

La plupart des conflits modernes sont **dissymétriques**, c'est-à-dire du fort envers le faible dans le cadre d'un conflit régulier avec des cibles militaires. À l'inverse, un **conflit asymétrique** est du faible envers le fort, par l'opposition de la force armée d'un état face à des combattants (résistants, rebelles, guérillas, terroristes,...) où ces derniers sont présents. Ces combattants se servent des points faibles de l'adversaire pour parvenir à leurs objectifs. Les **environnements asymétriques** sont donc les lieux où ces confrontations se produisent. Ces confrontations vont des manifestations pacifistes avec la présence de forces de sécurité pour les protéger, les encadrer ou les disperser jusqu'aux actions terroristes dont l'objectif est d'infliger le plus de dégâts physiques et psychologiques avec le moins de coûts et d'efforts possibles.

B. Comportements récurrents dans les environnements asymétriques

Les environnements asymétriques **virtuels** de type "*Serious Game*" et **réels** de type JUO (*Joint Urban Operation*), MOUT (*Military Operation in Urban Terrain*) [Sukthankar and Sycara, 2005b] et MOOTW (*Military Operation Other Than War*) ont permis de répertorier les comportements typiquement militaires dont les forces de sécurité ont besoin d'obtenir une évaluation de la situation. En effet, différents **comportements collectifs** y sont produits de manière récurrente et **déjà détectable** par les récents systèmes :

- ✘ [Sukthankar and Sycara, 2005b] : sécuriser le périmètre, approcher le bâtiment, entrer dans le bâtiment, fouiller le bâtiment, maintenir / évaluer la sécurité, évacuer le bâtiment, maintenir la perspective d'un ennemi, maintenir une évaluation de la situation et se projeter dans le futur.
- ✘ [Luotsinen et al., 2007, Luotsinen, 2007] : Dans un contexte de champ de bataille, le leader sélectionne la tactique la plus appropriée en estimant les caractéristiques de l'environnement et les contacts ennemis potentiels. Pour une équipe militaire, même si les équipements évoluent, les **tactiques de mouvements principaux** restent fondamentalement inchangées et sont :
 - ✓ *traveling* : une vitesse élevée et coordonnée des unités de l'équipe quand il n'est pas prévu de contact avec l'ennemi ;
 - ✓ *traveling overwatch* : quand il y a un possible contact avec l'ennemi, l'unité de tête est en mouvement continu pendant que les autres unités alternent entre vitesse et sécurité ;
 - ✓ *bounding overwatch* : en attente d'un contact avec l'ennemi, pour maximiser la sécurité, chaque unité arrivant en tête s'arrête et surveille tant qu'elle n'est pas la dernière unité avant de reprendre le mouvement.
- ✘ Des **formations fondamentales d'équipes** (*column, line, wedge, vee, echelon (left ou right)*) sont utilisées en combinaison des mouvements tactiques pour faciliter les besoins en sécurité (exemple : protection des flancs ou support par un feu lourd). La formation utilisée est choisie en fonction de la mission (les objectifs à atteindre, les possibles positions ennemies, les conditions météorologiques et environnementales).

- ✦ Durant un exercice de guerre, **cinq types d'événements** sont généralement utilisés pour décrire les actions effectuées par les agents :
 - ‡ le *state event* : rapportant la position, l'orientation, la vitesse, l'accélération, l'état et le rôle de chaque acteur, ce qui est appelé le TDF (*Teamwork Data Format*) ;
 - ‡ le *fire event* : lorsqu'un acteur attaque un autre acteur ;
 - ‡ le *hit event* : lorsqu'il y a un impact d'une attaque sur un acteur ciblé ;
 - ‡ le *detonation event* : rapportant la position et les résultats d'une détonation ;
 - ‡ et le *LRF event* : pour l'usage d'un laser télémètre.
- ✦ En conclusion, dans un scénario d'exercice MOUT :
 - les **comportements collectifs** les plus probables sont : *column formation traveling, line formation traveling, box (combined line and column) formation, team split, team merge and bounding overwatch* (ce qui signifie "l'équipe se stoppe, se sépare en deux, une sous-équipe avance tandis que l'autre garde sa position jusqu'à ce qu'ils échangent leurs rôles"),
 - dont les **actions observables** les plus probables des agents sont : *move, feed, multiply, attack, flee*,
 - où les **critères de succès** sont : les agents ont rassemblé un maximum de ressources, ont consommé un minimum de ressources, ont le plus gagné face aux plus grands nombres d'ennemis et ont survécu en plus grand nombre à la fin du scénario.

Le **contexte** des situations asymétriques a amené la littérature scientifique sur ce sujet à une **description orientée sur les comportements collectifs militaires plus que ceux des civils**. Les forces de sécurité ont un besoin de comprendre la situation afin de planifier leur propre stratégie. Ce genre de situation peut être évaluée.

C. Formalisme d'une situation évaluée

L'**évaluation de la situation** (*situation awareness, SA*), selon [Endsley, 1995], est définie (après traduction) comme étant "*la perception des éléments de l'environnement dans un volume de temps et d'espace, la compréhension de la situation et leur projection de leur statut dans le futur proche*". Cette conscience de ce qui est en train d'être observé est ce que nous cherchons à obtenir dans le contexte d'une situation surveillée.

Dans cette définition, nous distinguons trois niveaux indépendants (observables dans la Figure 2.1) :

Level 1. La perception des éléments de l'environnement ;

Level 2. La compréhension de la situation actuelle ;

Level 3. La projection des futurs états.

Le schéma 2.1 nous montre où est située la **conscience de la situation** dans le mécanisme d'une architecture cognitive (d'un agent au niveau micro). Une autre étude [Endsley, 1997] démontre que la **perte** de la conscience de la situation, due à la combinaison de plusieurs facteurs (telle que la mauvaise communication entre automate et humain qui a engendré le choix d'une suite d'actions incorrectes), peut être évitée s'il y a seulement la **communication des informations pertinentes** pour engendrer des actions quasi réactives. Sinon les décisions prises peuvent aller à l'encontre des objectifs recherchés. Dans notre sujet, cela nous interpelle que nous devons produire et communiquer seulement les informations de haut niveau qui seront utiles aux utilisateurs. Par exemple, l'utilisateur n'a pas d'intérêt à être signalé chaque fois qu'un groupe change de comportement alors que ce nouveau comportement est encore considéré comme normal.

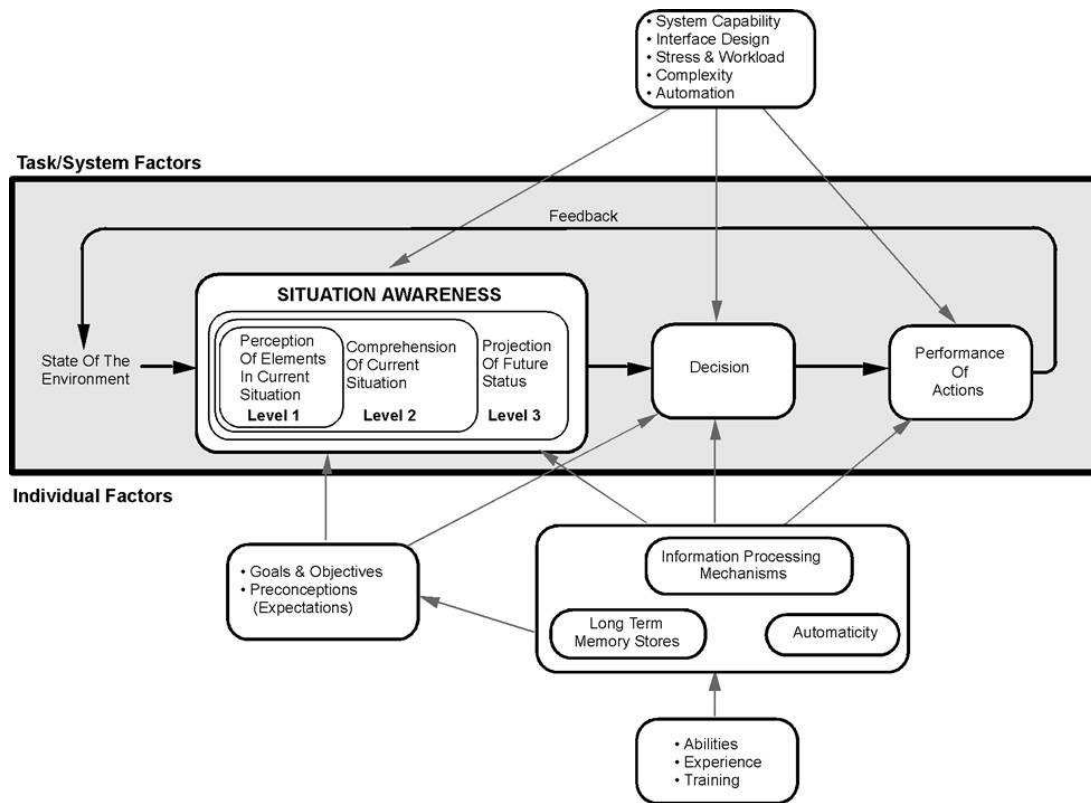


FIGURE 2.1 – Le modèle (SA) d'évaluation de la situation (adapté de [Endsley, 1995])

[Hicks et al., 2004] ont démontré que des systèmes SA peuvent servir d'**aide à la décision sous incertitude** pour des opérations risquées de type militaire. Ceci permet d'obtenir rapidement une vue dégagée de la situation pour planifier un modèle opérationnel efficace sur la base d'informations acquises par le processus de fusion de données.

Selon le même auteur, l'**objectif de tout système SA** est de suivre et d'utiliser toutes les informations disponibles dans le temps opportun pour l'objectif de la planification tactique et de la prise de décision. Pour **tenir compte de l'incertitude** (i.e. les informations incomplètes, confuses, partiellement correctes), le processus de jugement se base sur "*l'expérience acquise, la connaissance historique, en effectuant des hypothèses sur l'état, les intentions et méthodes des agents rencontrés*" (sachant que leur comportement est rationnel, cherchant à maximiser leurs profits et minimiser leurs pertes). C'est à ce moment que des **biais** peuvent apparaître dans les prises de décisions : "*la fatigue, le stress, les enjeux, les préjugés, les erreurs, les croyances, les intuitions, la tendance à la partialité par l'ignorance, la décision par similarité, la croyance de corrélation aléatoire, la grande influence de la première fois, la conclusion avant les preuves, les contradictions avec les croyances non prises en compte, l'accent injustifié d'informations interprétées comme plus flagrantes...*" qui modifient la pensée et l'objectivité. Ces **lacunes** humaines doivent être prises en compte pour les corriger avec l'aide d'un système SA qui se base sur l'**infobésité** disponible (i.e. la surcharge d'information).

En parallèle, [Adams, 2007] donne une **définition décomposée** de la conscience de la situation par la formule : $SA = (Niveau_d'_autonomie \times C) \cup E \cup X$ où représente :

- Niveau_d'_autonomie pour les caractéristiques spécifiques associées au niveau d'autonomie ;

- *C* pour les différents facteurs : travail, stress, attention, perception, mémoire, vigilance. . .
- *E* pour les caractéristiques de l'environnement : terrain, lieu, temps, exigences opérationnelles. . .
- *X* pour les caractéristiques liant *C* et *E* : l'entraînement, les capacités, la complexité des tâches, les erreurs de communication. . .

Une SA doit donc présenter le résultat dans la forme qui convient le mieux à l'agent pour effectuer sa décision (de manière à être compris instantanément pour les options opérationnelles). Il existe d'autres auteurs ayant apporté d'autres réponses, mais ces trois approches représentent l'idée générale de ce qu'on attend d'une conscience de la situation obtenue par un système informatique de détection. Le domaine de SA est très large, mais dans tous les cas, elle se repose sur la technologie de fusion de donnée afin d'être produite.

2.1.2 Origine de la fusion de données

Le domaine de la fusion de données est l'approche la plus **élémentaire** pour obtenir des informations sur les entités présentes dans un environnement observé par des capteurs. La fusion de données suit principalement un modèle sur plusieurs niveaux de traitement de l'information que nous allons expliquer.

La prise de conscience réelle des potentialités de la fusion s'effectue depuis [Fortmann et al., 1980], par l'exploitation des données radar avec des techniques statistiques. La fusion a d'abord été privilégiée par son besoin militaire crucial avec l'apport d'outils d'intelligence artificielle. C'est ainsi qu'à l'origine un amalgame a été fait entre fusion de données et fusion de capteurs. Leur distinction a depuis été faite :

- ▷ La **fusion de capteurs** traite de la combinaison d'informations issues de différents capteurs (i.e. radars, caméras infrarouge ou visible, mais également lasers, capteurs ultra violet, ultrasons, sismiques, . . .).
- ▷ La **fusion de données** se veut plus générale, puisqu'elle s'intéresse à toute source d'information, qu'elle soit issue de capteurs, comme précédemment, ainsi que de systèmes de navigation (gyromètres, centrales d'attitude, . . .), de bases de données diverses (données cartographiques, documentaires, modèles numériques de terrain, règles de savoir-faire, . . .), voire d'analyses et/ou de fusions précédentes.

Au niveau **macro**, le domaine spatial (tel qu'un territoire historiquement cartographié) observe des phénomènes à dynamique lente et correspond à une analyse stratégique de la situation. Au niveau **méso**, la surveillance du champ de bataille s'intéresse aux processus à dynamique plus rapide et relève de l'analyse tactique. Il se pose ici la question du niveau de dissémination des données et du degré d'abstraction de l'information qui en est extraite. Nous en distinguons plusieurs fonctions de base : **la veille et la détection, la classification et l'identification** (à chacune étant associée un ou plusieurs capteurs, qui dans ce cas devront être combinés).

En fonction de la situation, par exemple traquer un objectif, il nous faut des données issues d'un réseau de multiples capteurs. Ces données sont de nature différente (i.e. selon chaque type de capteurs), nous devons alors fusionner les informations. En premier lieu, le processus fusionnera les sources d'information ayant les mêmes origines. Dans un deuxième temps, il reste à fusionner les différents types de sources. Ce dernier traitement conduit à une fusion de données imposant une capacité d'interprétation des données plus exigeante pour en éviter la perte et/ou l'infobésité. C'est lors d'un processus de fusion que nous nous rendons compte qu'une donnée est sans intérêt si nous ne savons pas quel capteur la produite et ce que le capteur a surveillé.

A. Sources des données : des capteurs de surveillance

Pour choisir la bonne approche de fusion de données, il nous faut déjà connaître les types de sources de données dont nous disposons.

Dans le cadre de la surveillance de zone, de nos jours, les moyens de détections sont nombreux, variés et complémentaires selon l'objectif que nous recherchons :

- des capteurs linéaires positionnés sur le contour des zones à surveiller pour modéliser des systèmes de protection anti-intrusions ;
- des capteurs radars pour couvrir la zone à surveiller ;
- des capteurs optiques et sonores pour protéger les zones sensibles à fortes impossibilités de détection par les autres méthodes (bâtiments, zones boisées, . . .) ;
- des agents mobiles (drones, humains, animaux) pour les capacités de déplacements. Différentes catégories de drones peuvent être utiles :
 - ★ les drones à voilure tournante surveillent la zone, recherchent des intrus quand il y a le déclenchement d'une alarme et les poursuivent s'ils sont perçus.
 - ★ les drones à voilure fixe ont une capacité de mouvement réduit et sont donc utilisés pour la surveillance de zone sensible fixe.

Parmi les différents capteurs opérationnels français qui sont utilisés pour la surveillance de champ de bataille, chacun fournit différentes informations appelées rapports [Pannetier, 2006] pouvant être du type :

- ROEM (*Rapport d'Origine Electro-Magnétique*) issue des capteurs passifs ESM (*Electronic Support Measure*) délivrant des mesures d'angles ;
- ROHUM (*Rapport d'Origine HUMaine*) issue des capteurs humains présents sur le champ de bataille, délivrant des données de positionnement et de classification ;
- ROIM (*Rapport d'Origine IMage*) issue des capteurs images SAR (*Synthetic Aperture Radar*), EO (*Electro-Optic*) et IR (*Infra-Red*) délivrant des données de positionnement et de classification ;
- RORAD (*Rapport d'Origine RADar*) issue de capteurs actifs GMTI (*Ground Moving Target Indicator* étant des systèmes d'observations aéroportés) délivrant des mesures d'angle, de distance et de vitesses radiales.

Si nous prenons l'exemple de [Pannetier, 2006], des GMTI permettent de détecter les cibles en mouvements en mesurant l'effet *Doppler*⁹. L'analyse physique du signal permet d'obtenir une mesure élémentaire appelée un plot MTI. Dans le repère capteur, un plot MTI contient les variables {distance, angle, vitesse radiale} entre le capteur et l'objet détecté. Ainsi pour tous les objets détectés, un ensemble de plots MTI est fourni à chaque instant d'acquisition du capteur. Ce pistage se base sur la prédiction de sa trajectoire suivant un modèle dynamique (i.e. mis à jour et corrigé avec chaque nouveau plot MTI). En définitive, la poursuite informe sur l'évolution temporelle (en temps réel) de la cible et permet d'obtenir ses caractéristiques cinématiques détaillées.

Les capteurs sont plus ou moins limités selon leur capacité de manœuvre, leur précision (produisant plus ou moins de bruit), la densité de trafic et la topologie du terrain observé. Les capteurs sont donc tributaires des conditions de détection qui peuvent être liées aux objets d'intérêt et à leur comportement.

De manière générale, ces types de capteurs vont nous permettre d'obtenir des informations à propos de chaque entité de la situation tels que : la position, la vitesse, l'orientation, le type, . . . Un dernier

9. L'effet Doppler est le décalage de fréquence d'une onde acoustique ou électromagnétique entre la mesure à l'émission et celle à la réception lorsque la distance entre l'émetteur et le récepteur varie au cours du temps

problème reste les fausses alarmes, mais les approches en fusion de données permettent de réduire ces problèmes. Nous retrouvons ce principe notamment dans le modèle de fusion suivant qui est le plus utilisé par la communauté scientifique.

B. Modèle JDL de fusion de données

Le modèle JDL de fusion de données va nous permettre déterminer précisément à quel niveau d'observation notre problématique se situe dans le processus de l'évaluation de la situation.

La **complexité** du processus d'ingénierie de système de fusion de données se retrouve dans :

- ◇ la représentation de l'**incertitude** dans les observations issues de phénomènes perçus ;
- ◇ la combinaison d'informations **hétérogènes** ;
- ◇ la mise à jour et la manipulation de l'énorme **quantité** d'observations à propos des entités multiples par l'utilisation de méthodes d'association et d'interprétation (complémentaires et parfois alternatives).

Pour développer et évaluer des processus (automatique, semi-supervisé ou manuel) de fusion de données, l'**identification de la similitude** est l'approche utilisée. Il s'agit du même problème d'association et de combinaison de données effectué par la conscience humaine. Cette complexité a produit une catégorisation fonctionnelle commune et vérifiée par la communauté d'experts en fusion : le *JDL Data Fusion model* datant de 1985 par l'*U.S. Joint Directors of Laboratories (JDL) Data Fusion Group*. Ce **modèle JDL de fusion de données** [Liggins et al., 2008] est le système le plus couramment employé pour classer les fonctions de fusion de données.

La définition des différents niveaux de fusion de données du modèle JDL a suivi une évolution :

▷ Le lexique initial du *JDL data fusion 1985* [JDL, 1991] définit la **fusion de données** comme étant : "*Un processus traitant l'association, la corrélation, et la combinaison des données et l'information des sources simples et multiples, pour réussir à raffiner la position, les évaluations identitaires, et les estimations complètes et opportunes des situations, des menaces et leur signification. Le processus est caractérisé par des mises au point continues de ses évaluations et estimations, et l'évaluation du besoin de sources additionnelles, ou de la modification du processus lui-même, pour réaliser des résultats améliorés.*"

▷ Étant trop restrictive, la définition initiale a été révisée [Steinberg et al., 1999, Llinas et al., 2004]. Elle saisit maintenant les différences significatives dans les types de données d'entrées, modélisées et en sorties. L'inférence y est alors appropriée aux grandes catégories de problèmes de la fusion de données. Un créateur de système de fusion doit donc déterminer quels seront les types d'entités de base à partir desquels des relations seront définies.

▷ Dans [Liggins et al., 2008], les deux définitions suivantes des niveaux de fusion de données du modèle JDL ont été proposées :

▷ [Steinberg and Bowman, 2004] ont suggéré la (plus référencée) définition des niveaux de fusion de données du modèle JDL accompagnée du schéma 2.2. Ce schéma présente un partitionnement en niveaux pour distinguer les différents problèmes de fusion. Toutefois, les auteurs indiquent que cette définition donne un modèle fonctionnel à interpréter selon le besoin utilisateur.

▷ [Blasch, 2008] les a alors aussi redéfinis en incorporant un 5^{ème} niveau pour son orientation appliquée au *pistage de groupe* depuis [Blasch and Plano, 2002], ce qui est plus proche de notre sujet sur les comportements collectifs.

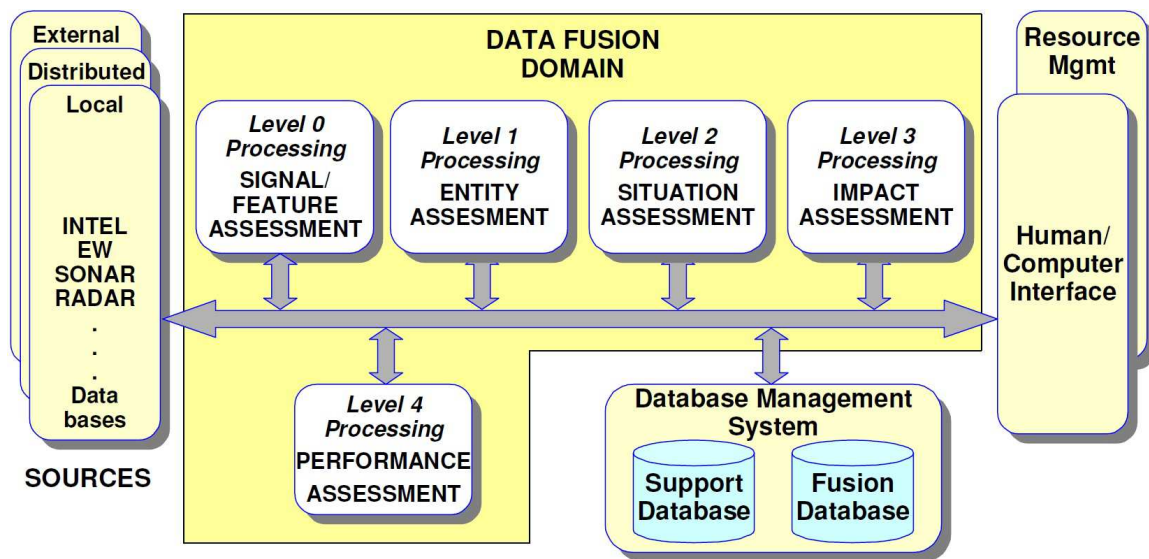


FIGURE 2.2 – Le modèle de fusion de données révisé et recommandé [Steinberg and Bowman, 2004]

▷ Par la suite, [Blasch et al., 2012] l'ont orientée sur *l'évaluation de la situation* et propose la définition du modèle DFIG (*Data Fusion Information Group*¹⁰) qui conserve la structure du modèle JDL en mettant l'accent sur les besoins en HLIF (haut niveau de fusion de l'information) et en gestion des ressources (notamment les besoins des utilisateurs) :

- Niveau 0 : *Data assessment* - L'évaluation des données : l'estimation et la prédiction des états observables des signaux / objects en se basant sur une association de données au niveau du signal / pixel.
- Niveau 1 : *Object assessment* - L'évaluation des entités : l'estimation et la prédiction des états des entités en se basant sur l'association de données, l'estimation des états continus et discrets.
- Niveau 2 : *Situation assessment* - L'évaluation de la situation : l'estimation et la prédiction des relations entre les entités, y compris la structure des forces et les rapports de force, les communications,...
- Niveau 3 : *Impact assessment* - L'évaluation de l'impact : l'estimation et la prédiction des effets sur les situations des actions planifiées ou estimées par les participants, y compris les interactions entre les plans d'action des multiples acteurs.
- Niveau 4 : *Process refinement* - L'amélioration des processus (un élément de la gestion des ressources) : l'acquisition et le traitement de données à mettre à jour pour soutenir les objectifs de détection.
- Niveau 5 : *User Refinement* - Le retour de l'utilisateur (un élément de la gestion des connaissances) : le fait de déterminer qui interroge les informations, qui a accès aux données (mises à jour), et qui est l'équipe qui a pris part à la décision des actions.
- Niveau 6 : *Mission management* - La gestion de la mission (un élément de gestion de plate-forme) : L'établissement adapté du contrôle spatio-temporel des actifs par la planification de l'itinéraire et de l'objectif (soutenu par l'équipe de décision des actions) selon les contraintes sociales, économiques et politiques.

10. Le DFIG est un groupe d'auteurs ayant travaillé ou sont fortement corrélés au modèle JDL dont [Steinberg and Bowman, 2004].

Dans tous les cas de modèles de fusion de données, outre le traitement local de ces informations, celles-ci devront être transmises aux échelons supérieurs pour agrégation, synthèse, confrontation avec d'autres en vue d'une analyse globale et d'une éventuelle décision d'action. [Liggins et al., 2008] présente un état de l'art complet portant sur les niveaux 0 (traitement du signal) et 1 (estimation des entités), notamment dans le pistage de cible multiple (*multi-target tracking*). Le HLIF, associé aux niveaux suivants, est devenu le moteur principal des recherches actuelles où sont tentées de nouvelles bases unifiantes et théoriques (telles que le DIFG [Blasch et al., 2012]). **Le sujet de cette thèse que nous résumons par "la détection de comportement collectif pour l'évaluation de la situation" se situe entre les niveaux 2 et 3 des modèles DFIG (et JDL) de fusion de données :**

✘ Nous prenons en entrée les données issues "l'évaluation des entités" du niveau 1, notamment du *multi-target tracking* ;

✘ Nous effectuerons "une estimation de la situation" du niveau 2 par **la détection** des relations entre les entités, notamment **des groupes et de leurs comportements** ;

✘ Nous achèverons "l'évaluation des impacts" du niveau 3 par **l'anticipation des objectifs et des intentions des entités**.

De nos jours, si nous désirons obtenir des données exploitables dans un cas de foule vidéo-surveillée par un réseau multi-capteurs, il nous faut un système de fusion de données du niveau 0 à 2 développés par un grand nombre d'experts pour chaque type de signaux/capteurs. Cependant, **un capteur parfait** a fait son apparition il y a quelques années et sa présence se généralise chez tous les individus : le **smartphone** (et anciennement le téléphone portable).

Avec les téléphones portables, la géolocalisation donne la position du téléphone en temps réel. L'arrivée des smartphones, de leurs senseurs (de types GPS et accéléromètres) et de sa propre capacité de calcul, permet une détection des événements dépendant à la fois du lieu et du moment. En effet, **cette chronolocalisation des mobiles** par le biais des réseaux télécoms et internet produisent la meilleure manière d'observer les déplacements que ce soit en termes de coût et de qualité de l'information, réduisant la difficulté de la fusion de données. L'exploitation des données d'un point de vue juridique est autorisée après un processus d'anonymisation qui pourrait être facilement mis en place [Giannotti and Trasarti, 2008, Giannotti et al., 2008]. En complément, une démarche de renseignement dans le cadre judiciaire permet de suivre spécifiquement certaines cibles, de mettre en évidence leurs activités et d'observer d'éventuels impacts sur le reste de la foule. Les comportements collectifs indésirables sont souvent dus à un événement déclencheur (accidents) ou des individus produisant des comportements déviants (auteurs de troubles).

Nous ne nous sommes donc pas intéressés à la manière d'obtenir les données d'observations issues des niveaux précédents (0 à 1). Nous avons préféré nous concentrer sur les approches qui prennent en entrée ce niveau 1 d'observations déjà traitées. À ce niveau d'observation, notre objectif est l'identification des groupes et des comportements déviants (ce qui est l'intitulé de la section suivante) dans les environnements asymétriques.

2.2 Identification des groupes et des comportements déviants

La première étape dans notre évaluation de la situation d'environnement asymétrique est de prendre les résultats du suivi multi-cibles afin d'identifier les groupes. Les comportements déviants seront alors moins complexes à distinguer parmi les comportements collectifs d'une foule surveillée.

2.2.1 Suivi de multiple personnes

Nous accordons une certaine importance aux techniques de suivi de multiples personnes (*multi-people tracking*) multi-modales (i.e. s'appuyant sur un réseau de multiples capteurs). Ce domaine de recherche fait encore, de nos jours, preuve d'innovation. Au travers du pistage des individus et de la reconnaissance des équipes, elle nous permet la modélisation des groupes afin de **réduire la complexité** de l'identification des comportements collectifs.

De nos jours, les lieux publics sont souvent surveillés par des réseaux multi-capteurs : caméras visibles ou infrarouges, détecteurs de fumées et sonores,... et la vidéo surveillance publique est une pratique de plus en plus généralisée. Une telle quantité de données est ingérable pour des humains, surtout si ceux-ci doivent détecter des problèmes pouvant s'y produire et décider de certaines actions. La demande de solutions (semi-)automatiques de surveillance a évolué :

1. La sauvegarde et le classement des données ; Exemple : l'objectif est l'interrogation de la base de données pour obtenir les faits reliés à un événement passé (ayant posé problème) ;
2. Les premiers prétraitements pour ne garder que les données utiles ; Exemple : seule la présence de mouvements déclenche l'enregistrement ;
3. La mise en place d'alertes automatiques quand des capteurs atteignent certains seuils de tolérance ; Exemple : des capteurs de fumée pour les alarmes incendie automatique ou l'alerte automatique d'un surveillant quand le son capté par des microphones dépasse un seuil anormal de décibels (e.g. cris / paniques / violences verbales) ;
4. Le suivi automatique d'un (groupe d') individu(s) sur les données sauvegardées, puis en temps réel, jusqu'à des tentatives d'anticipation. L'objectif reste de savoir si les comportements surveillés sont normaux, anormaux, suspicieux ou malveillants. Les solutions exigées vont de la reconnaissance *offline* (i.e. après l'événement), puis l'identification en temps réel et enfin leur anticipation pour permettre une alerte (donc une action préventive).

Les **objectifs** principaux de la **surveillance publique** sont de pouvoir diminuer les coûts engendrés par la surveillance humaine (et ses possibles défaillances) et d'éradiquer les événements problématiques (d'où ce besoin de protection constante). Lorsque la **population a connaissance** que ce sont des systèmes automatiques qui gèrent cette surveillance pour leur propre sécurité, la pratique intrusive de la surveillance des lieux publics est de plus en plus **acceptée**. Un automate est préféré à un être humain qui aurait la possibilité d'observer la vie privée de la population. Ainsi la demande de solutions toujours plus innovantes est apparue pour l'extraction d'informations issues de multiples capteurs, la fusion de données, le suivi multi-cibles et les alertes automatiques.

En se basant sur les méthodes de suivi multi-cibles [Cupillard et al., 2002], le tableau 2.1 **définit les observations micro, méso et macro pour la représentation d'un comportement**.

	<i>Représentation d'un comportement</i>	<i>Reconnaissance</i>	<i>Exemples</i>
<i>États</i> (Une observation de niveau micro)	Un état est une situation décrivant un acteur à un temps t ou une caractéristique constante d'un acteur entre deux instants consécutifs. Dans le cas des comportements de groupe, un acteur est un groupe suivi ou une entité statique (telle qu'un équipement ou une zone d'intérêt).	Les états sont basés sur les méthodes numériques par les relations spatio-temporelles de leurs caractéristiques.	La position, la vitesse, le niveau d'agitation interne du groupe,...
<i>Événements</i> (Une observation de niveau méso)	Un événement est un changement d'état entre deux instants t consécutifs.	Les événements sont basés sur les méthodes de comparaison entre les états.	L'évolution de l'agitation de groupe
<i>Scénarios</i> (Une observation d'un niveau macro)	Un scénario est une combinaison des états et des événements. Les comportements sont spécifiques des scénarios (dépendant de l'application) définis par les observateurs.	Les scénarios sont basés sur les séquences temporelles d'événements.	Un combat de groupe représenté par une agitation global en constante augmentation.

TABLEAU 2.1 – Observation micro, méso et macro d'une représentation d'un comportement basée sur les méthodes de suivi multi-cibles.

La majorité des approches de surveillance pistent les humains individuellement. La nature humaine nous amène à nous déplacer en différents groupes qui se séparent et se forment selon les objectifs individuels. Ce dynamisme continu augmente la complexité pour le pistage individuel, mais diminue aussi celle du pistage de groupe. En effet, le fait de se déplacer en groupe produit un rapprochement des individus, des tentatives d'évitement de bousculades et réduit la vélocité du groupe. Un ensemble de méthodes a été développé pour identifier les groupes par le pistage de leurs activités collectives.

A. Pistage de groupe

Nous avons deux approches générales pour le pistage de groupe. L'une part du postulat **macro** que la foule est une seule entité qui se sectionne jusqu'au niveau micro. L'autre part du postulat *micro*, i.e. que les entités s'agrègent jusqu'au niveau macro. La première utilité est de pouvoir formaliser le comportement collectif d'un groupe plutôt qu'individuellement. Ceci réduit drastiquement la complexité de la modélisation et nous obtenons un niveau d'observation plus élevé de la situation.

La **proxémie** (Figure 1.1 page 19) est principalement utilisée dans les méthodes d'identification des groupes. Deux approches générales sont alors utilisées pour réduire les incertitudes et les incomplétudes lors du multi-pistage, qui peuvent se nommer :

▷ **Bottom-Up** : C'est un **regroupement hiérarchique du niveau micro à macro** où les paires (d'ensembles) d'individus les plus proches sont fusionnées. Ces observations individuelles sont fortement soumises aux incertitudes. Si nous prenons l'exemple de la séquence temporelle des positions des membres, alors la séquence temporelle de la position moyenne du groupe sera renforcée par chaque membre. En utilisant les séquences temporelles des observations individuelles, nous les synthétisons en

une observation de groupe de meilleure qualité.

▷ **Top-Down** : C'est un **découpage hiérarchique du niveau macro à micro** où les ensembles sont séparés en fonction des sous-ensembles les plus éloignés. Le processus consiste à estimer la dimension du groupe, puis suivre son évolution afin d'en extraire les trajectoires individuelles de ses membres. Dans certains cas, tels que les mouvements à plusieurs entités très rapprochées, les capteurs ont une grande difficulté pour percevoir les entités distinctement et en fournissent **des observations incertaines**¹¹ (i.e. **imprécises**¹² et/ou **incomplètes**¹³). Pour y pallier lorsqu'une entité est reconnue à deux moments consécutifs dans un même groupe, le mouvement du groupe est fourni pour représenter les observations manquantes de cette entité.

Les résultats des deux approches *top-down* et *bottom-up* peuvent être représentés en un arbre où les feuilles sont les individus (micro), les branches sont les groupes (mésos) et la racine est la foule (macro). Quel que soit le sens de parcours de l'arbre, nous pouvons pister les groupes et estimer le nombre de ses membres.

[Lau et al., 2010] propose une approche de **clustering** (équivalent à du regroupement / découpage hiérarchique) sur les données obtenues de scanners laser (telles que les positions cartésiennes des entités) :

- Cette approche appelée **extended Multi-Hypothesis Tracking** produit à la fois des hypothèses sur les *modèles* (chaque possible partitionnement des traces du groupe) et les *assignments* (l'association stochastique des traces en observation) qui sont mis à jour tout au long du cycle de pistage. Il en est estimé le nombre de membres et l'historique des interactions de groupes (fusion, séparation,...). Chaque mouvement de groupe est modélisé en une matrice de transition basée sur les traces observées.

✓¹⁴ Ces modèles permettent d'estimer l'état actuel le plus probable. Celui sélectionné est le plus proche parmi les modèles préalablement définis. Basiquement, la **probabilité qu'un individu appartienne à un groupe** est estimée par une fonction de distance entre le mouvement de l'individu et celui du centre du groupe (appelé le **centroïde**). Aux niveaux hiérarchiques supérieurs, la probabilité d'une interaction entre deux groupes en mouvement est estimée de la même manière sur leurs deux **centroïdes**.

✗¹⁵ Tant que les groupes en mouvement ne se croisent pas, [Lau et al., 2010] fournit une méthode adéquate pour le suivi (et l'estimation de la taille) des groupes. Néanmoins, l'approche *clustering* produit une fusion des deux groupes puis une séparation sans donner la possibilité de savoir si ce sont les mêmes groupes avant et après l'interaction. Pourtant, le mouvement devrait permettre de discriminer les groupes.

[Cupillard et al., 2002] présente un processus pour la reconnaissance de comportements de groupes de personnes dans les stations de métro en utilisant de multiples caméras.

- Sur la vue 2D de chaque image, les objets mobiles sont reconnus par les pixels changeants. Chaque objet mobile observé par une caméra est fusionné avec ceux des autres caméras en se basant

11. **L'incertitude dans la séquence d'observation d'une entité** est lorsque les données des observations sont imprécises et/ou incomplètes. Le capteur qui a fourni les données à propos de l'entité et/ou l'analyseur qui a créé l'observation de l'entité en se basant sur ces données sont à l'origine de ce problème.

12. L'observation d'une entité est **imprécise** quand il y a un doute sur la fiabilité des sources de l'information.

13. La séquence d'observations d'une entité est **incomplète** quand il manque au moins une observation d'un instant t . Une observation est **partielle** (i.e. incomplète) quand l'observation inclut seulement une partie des données habituellement fournies.

14. Le symbole "✓" signifie "Avantage(s)" et est utilisé tout au long du manuscrit pour éviter la répétition.

15. Le symbole "✗" signifie "Limite(s)" et est utilisé tout au long du manuscrit pour éviter la répétition.

sur la combinaison de matrices 3D contenant la position, la dimension et la trajectoire temporelles. Les entités mobiles d'un même groupe sont synthétisées en une seule entité (de groupe) d'objets mobiles.

✓ Le système peut ainsi détecter les comportements de groupes qui se combattent ou bloquent une voie (avec un taux correct de détection [70% ; 95%]).

✗ Par son approche **déterministe** des **automates**, il y a un nombre important de fausses alarmes qui pourrait être réduit par l'utilisation de techniques d'apprentissage et de reconnaissances stochastiques (telles que les réseaux Bayésiens dynamiques).

La meilleure approche *bottom-up* que nous avons trouvée est sans doute celle de [Chang et al., 2011]. Elle utilise la proxémie et son historique afin de suivre l'évolution de chaque groupe indépendamment et les interactions avec les autres groupes (ou individus seuls). Le processus est en deux étapes :

(1) Une *analyse probabiliste de groupe* raisonne à propos de la structure du groupe basée sur un graphe de connectivité entre les individus ;

(2) Une *analyse probabiliste du mouvement* raisonne sur le motif spatio-temporel entre l'individu et le groupe pour permettre une reconnaissance du scénario.

- Le résultat est un graphe de connectivité entre les individus. Chaque paire d'individus a une connexion évaluée sur l'historique de leur proxémie dénommée par le terme de *pairwise grouping measure* (PGM) qui définit une probabilité entre deux personnes sur : un vecteur de position relative (la distance), un vecteur de vitesse relative (le mouvement commun) et l'historique du pistage (*tracking*). Ensuite, il est calculé la *path-based group connectivity* pour que le graphe de connectivité ne garde qu'un chemin optimal pour chaque paire d'individus (i.e. le chemin ayant la plus forte PGM en passant par des paires intermédiaires). Les sous-graphes obtenus sont considérés comme étant des groupes.

✓ Si le processus s'arrête à cette étape de l'analyse probabiliste de la structure de groupe, alors elle permet qu'un même individu appartienne à différents groupes en mouvement. Ces groupes sont détectés en formation, en dispersion ou stables selon l'évolution de la connectivité mesurée.

✗ Lorsque les observations des entités individuelles (issues du suivi multi-cibles) sont partielles et/ou incomplètes, cette qualité peut fausser toute la base des calculs de mesure de la connectivité. C'est le **problème** de toutes les approches *bottom-up*.

Ces approches (*bottom-up / top-down*) sont des solutions de pistage des groupes (variables en nombre de membres) sur le court terme. Pour les appliquer sur le moyen terme, il nous faut un niveau d'observation plus précis, notamment par la prise en compte du rôle des agents pour reconnaître les activités coopératives observables. Le fait de pister les mêmes groupes (pouvant être dynamique en membres) sur le moyen terme, par une prise en compte du rôle des membres, nous fait passer d'une étude des approches de **pistage de groupe** à celles de **reconnaissance d'équipe**.

B. Reconnaissance d'équipe

Une **équipe** peut se diviser en sous-équipes agissant en parallèle, fusionner avec d'autres groupes pour des tâches plus exigeantes et s'en séparer quand les plans sont terminés. Ici nous faisons apparaître une **complexité** additionnelle : les groupes peuvent être **dynamiques** (i.e. un nombre variable de membres au cours du temps). Contrairement à un groupe qui ne suit qu'un objectif commun, une équipe suit un **objectif partagé** et connu de chacun des membres. Les membres vont effectuer une séquence ordonnée d'actions (préalablement consenties ou non) pour permettre l'atteinte des objectifs partagés puis individuels. Nous parlons ainsi de reconnaissance et non pas d'identification puisqu'il sera difficile

d'identifier (i.e. de comprendre en temps réel chaque nouvelle action coopérative) des comportements d'équipes ; ce qui l'est moins pour leur reconnaissance si ceux-ci ont été modélisés préalablement.

Lorsque les groupes disposent d'une action plus collaborative que collective, nous nous trouvons dans le cadre de la reconnaissance d'équipe. Cette dernière a été développée selon plusieurs approches, mais avec un seul point de vue : **un groupe est considéré comme une équipe lorsque les membres exécutent un rôle qui a un sens par rapport à l'équipe**. Pour la reconnaissance d'équipe, les principaux travaux sont récents et issus de [Sukthankar, 2007, Luotsinen, 2007].

L'objectif de l'analyse des activités en équipe [Sukthankar, 2007] est d'identifier le but de l'équipe, les actions exécutées par les membres pour atteindre ce but et les règles de coordination entre ses membres. Trois classes générales de **caractéristiques** sont alors potentiellement valables pour la reconnaissance d'activités / plans d'équipes [Sukthankar, 2007] :

(1) les relations spatio-temporelles entre les membres des équipes et les repères physiques qui restent fixes sur une certaine période ;

(2) les dépendances temporelles entre les comportements lors d'un plan ou entre les actions d'un comportement d'équipe ;

(3) les contraintes de coordination entre les agents et les actions qu'ils produisent. Certaines propriétés des interactions observées sont invariantes quel que soit les possibles permutations parmi les comportements, mais la reconnaissance d'activité / de plan multi-agents inclut deux difficultés additionnelles [Sukthankar, 2007] :

1. les comportements multi-agents sont plus variables dans les traces¹⁶ spatio-temporelles observées que ceux des simples comportements ;
2. la composition de l'équipe peut changer au cours du temps.

Afin de détecter des **comportements d'équipes**, notamment par leurs activités collaboratives, nous pouvons nous appuyer sur la reconnaissance des rôles des agents.

- Pour chaque agent, les algorithmes *Unique* et *Multiple Role Assignment* (un agent est assigné à un seul ou de multiples rôles) de [Luotsinen and Boloni, 2008] sélectionnent le rôle ayant la plus haute probabilité (parmi ceux identifiés comme valides). Cette probabilité se calcule en suivant un arbre de décision stochastique appris. Le parcours s'effectue de la racine jusqu'aux feuilles des rôles, où chaque branche suivie (selon la valeur d'une variable observée) inclut une probabilité à multiplier par celle obtenue par le chemin déjà parcouru.

✓ La reconnaissance des rôles avant celle des activités d'équipe permet de renforcer les résultats de la seconde par une meilleure qualité de détection (notamment au niveau du taux de précision de reconnaissances correctes de quel membre appartient à quelle équipe et pendant quel laps de temps).

✗ Pour chaque activité d'équipe, la librairie¹⁷ les contenant doit inclure toutes les permutations possibles en nombre de membres et de rôles. La reconnaissance est ralentie en fonction du nombre d'activités de la librairie. Nous retrouvons cette limitation dans l'algorithme *Multi-Agent Plan Recognition* [Banerjee et al., 2010]. En effet, cette méthode identifie les variables des comportements des agents dans l'équipe par une matrice P_{ij} , où p_{ij} est l'action attendue par le membre (de la ligne) j à l'étape (de la colonne) i et doit être comparé à chaque plan d'équipe P modélisé.

16. Dans [Sukthankar, 2007], les observations des actions des agents sont incertaines et incomplètes, alors le terme "**trace**" est utilisé pour les désigner.

17. Le terme de "**librairie**" est parfois utilisé pour exprimer un ensemble de modèles où chaque modèle représente une action / une activité / un plan / ... tout comportement individuel et/ou collectif ayant été appris et pouvant être mis à jour.

Ces méthodes d'identification par les rôles s'apparentent aux approches de **planification distribuée** du domaine de la décision multi-agents. Leur modélisation nous permet d'éviter de se poser la question de quels éléments / paramètres / caractéristiques pourrait être observables dans l'ensemble des toutes les activités collectives possibles afin d'identifier les équipes. Toutefois, ils existent des approches de planification qui se rapprochent de l'identification des équipes où les rôles sont représentés par un niveau d'observation plus haut (e.g. leaders et suiveurs) :

◊ La **théorie des jeux stochastiques** [Shapley, 1953] (*Stochastic Games theory*) est un formalisme pour des situations où la récompense d'un agent ne dépend pas seulement de sa propre action, mais aussi celles d'autres agents. Les équipes sont reconnues de la même manière en se basant principalement sur la reconnaissance des activités des membres, en s'attendant à ce que chaque agent agisse en coopération avec des intentions dévoilées et non cachées.

◊ De manière générale, nous pouvons nous attendre à ce que tout groupe suive les règles de **flocking** [Reynolds, 1987] (Figure 1.7 page 29) : des mouvements cohérents, séparés et alignés sur ses proches voisins.

◊ Contrairement à un groupe, une équipe peut être composée d'un leader et suivra l'**équilibre de Stackelberg** [Canu et al., 2008]. Cet équilibre se produit dans une situation où le leader cherche à maximiser la récompense de son groupe et agira en sachant que ses actions auront une influence sur tout le groupe. Les groupes coopératifs tenteront de s'entraider au point d'atteindre l'**équilibre de Nash** : une situation où aucun agent ne peut changer son action sans réduire sa récompense.

Comme définition, [Sukthankar and Sycara, 2007] présente une **équipe** comme étant un sous-ensemble d'agents appartenant à un scénario observé, où chaque agent participe à une seule équipe à tout moment. Pour chaque agent, la séquence des **traces** observées a été exécutée selon un plan d'équipe et la connaissance des plans possibles permet de faire des **hypothèses** sur la constitution des équipes et où ils en sont dans l'accomplissement du plan reconnu.

• L'objectif de [Sukthankar and Sycara, 2007] est d'identifier, d'apprendre puis de reconnaître l'ensemble des plans d'équipes d'agents qui seraient **consistants** en fonction des séquences de traces observées. Puisque pour chaque plan, il peut y avoir de multiples assignements d'agents possibles, mais avec un seul état final recherché.

✓ L'approche permet une double fonction, la reconnaissance de l'équipe et la reconnaissance du comportement multi-agents coopératif. Cette approche est surtout une alternative à l'inférence Bayésienne puisqu'elle utilise une **méthode évidentielle** (et non probabiliste) basée sur la **théorie de Dempster-Shafer**.

• L'algorithme STABR (*Simultaneous Team Assignment and Behavior Recognition*) [Sukthankar and Sycara, 2006] assigne simultanément tout agent à une équipe et à un comportement à chaque étape temporelle (i.e. lors d'une nouvelle observation). La reconnaissance de la formation par l'algorithme RANSAC (*Random Sampling and Consensus*) génère des hypothèses d'équipes qui expliquent toutes les traces spatio-temporelles observées des membres.

✓ Dans le cas d'utilisation de [Sukthankar and Sycara, 2007], l'approche **évidentielle** a présenté une reconnaissance de comportements plus rapide en comparaison des approches probabilistes, ainsi que pour le réassignement des membres aux équipes.

✗ Toutefois, il y a une possibilité de ne pas obtenir une détection de la formation d'équipe et son comportement malgré toutes les hypothèses puisqu'il faut un résultat consistant.

✗ La composition dynamique des équipes exige une approche continue de réassignement de rôle. Cette méthode est applicable pour les équipes, mais inapplicable pour les groupes à cause de leur structure informelle qui produisent des activités collectives (i.e. sans l'obligation d'une coopération).

→ Notre point de vue est qu'un agent peut appartenir à différents groupes et équipes, tout dépend de l'interprétation. Par exemple, un ensemble d'individus, où les membres sont en train de se combattre, va être considéré comme un seul groupe par un observateur externe, mais chaque membre du groupe sait quelles sont les équipes en présence (i.e. la sienne et l'adverse).

À propos de ces derniers travaux, plus les processus de suivi de groupe tentent d'obtenir une compréhension plus précise de la situation observée et plus ces approches basculent de l'identification à l'apprentissage et la reconnaissance des comportements coopératifs. Notre intérêt est au contraire la modélisation des comportements collectifs de groupe et pas seulement les coopératifs. La modélisation des groupes par le centroïde peut être alors une piste pour répondre à notre besoin.

C. Centroïde, une modélisation de groupe

La modélisation d'un groupe est moins complexe au niveau **méso** et la solution souvent utilisée est la canonisation des variables du groupe :

- Afin de modéliser un comportement d'agents, le modèle doit être **canonique**¹⁸ [Sukthankar and Sycara, 2005a] quelque soit la position, la vitesse, l'orientation, l'échelle d'observation, le nombre d'agents et de buts.

- Pour une représentation canonique de l'état du groupe, le concept de **centroïde** est utilisé [Sukthankar and Sycara, 2005a]. Il correspond à un vecteur où chaque variable a comme valeur la moyenne de celles de tous les membres du groupe.

- ✓ En d'autres termes, les comportements de groupes sont définis sur leurs **mouvements relatifs** (et non seulement sur les variables absolues des agents) pour être identifiés quelle que soit la situation surveillée. Les caractéristiques extraites des modèles de comportements peuvent être ainsi **classifiées** par les informations minimales et discrétisées selon leur type : agent, groupe ou environnement. Quelles que soient l'incertitude et l'incomplétude des observations de chaque membre, celles-ci vont **renforcer** la qualité de celle du groupe au travers de ce centroïde. La complexité d'une situation représentée par n centroïdes de groupes est fortement plus simple à suivre qu'une foule de x individus.

✗ Le défaut principal d'un état centroïde est la perte des informations individuelles. Si un membre a un comportement erratique par rapport au groupe, le centroïde n'en sera affecté qu'au $1/n$ (n étant le nombre de membres).

- ◇ Comme solution, [Luotsinen and Boloni, 2008] propose les *Centroid-Relative Position Vector* (CRPV) (Figure 2.3) et *Role-Relative Position Vector* (RRPV) qui intègre le rôle des membres dans le *Idealized Team Action*. C'est un type de centroïde où les observations partielles et incertaines sont normalisées et qui s'appuie sur les rôles pour modéliser un comportement d'équipe (et pas seulement de groupe). Le centroïde CRPV inclut la position, la vitesse, l'accélération, l'orientation, la courbe de la trajectoire (et son degré) du groupe. Chacune de ses variables se discrétise facilement. Le RRPV, quant à lui, considère que la position centrale du groupe est le membre ayant le rôle le plus important du groupe (e.g. un VIP et ses gardes du corps, une victime et des malfrats,...).

18. Le passage à la forme canonique est un procédé qui transforme des données (dont plusieurs représentations sont possibles) vers un format "standard / commun". Ce format permet de faciliter les comparaisons de données (i.e. modèles) par une élimination des données superflues, un ordonnancement des éléments,... En d'autres termes, la canonisation permet d'améliorer l'efficacité des algorithmes de reconnaissance.




FIGURE 2.3 – Le centróide CRPV [Luotsinen and Boloni, 2008] avec une équipe de trois agents.

Les résultats de traitement de fusion de données, tels que le multi-pistage, nous donnent une première compréhension automatisée de la situation à propos des entités et groupes en présence. L'utilisation du **centróide** réduit fortement la complexité pour les approches de modèles de comportement que nous découvrirons. Imaginons qu'un système de surveillance observe une foule, alors il sera plus simple d'identifier les comportements normaux et déviants avec un modèle d'observation de niveau **méso** comme le centróide (pour chaque groupe).

2.2.2 Comportements déviants (anormaux, inattendus et suspicieux)

En possédant assez de données d'un environnement surveillé, un expert peut utiliser des méthodes statistiques afin de déterminer les motifs de données indiquant quand les comportements sont normaux et suspicieux. Les autres seront considérés comme anormaux par le fait qu'ils sont inattendus. Mis en place dans un système de surveillance, l'objectif de l'identification des comportements **déviants** est principalement l'automatisation d'alertes et d'aide à la décision pour les forces de sécurité présentes.

La question est quand décider si une trace d'événement observée correspond à un comportement normal ou suspicieux [Kaluža et al., 2012] :

- (i) il n'y a pas d'événement / incident significatif qui aiderait à prendre la décision ;
- (ii) nous n'avons aucune idée sur des projets que pourrait avoir une personne malveillante ;
- (iii) les événements déclencheurs comportent tous les interactions qui requièrent leur identification ;
- (iv) le degré de suspicion dépend du comportement de l'agent dans le passé.

Les comportements **suspicieux** peuvent être inférés d'une combinaison d'événements multiples, où un événement se réfère aux interactions d'individus avec d'autres. Une simple observation d'événements n'est pas suffisante pour déterminer si le comportement d'individus est suspicieux.

Plusieurs types de comportements sont à identifier dans une situation asymétrique observée : les **normaux** et les **déviants** qui incluent les malveillants, les suspicieux, les inattendus et les anormaux. La variabilité des comportements est telle que les approches ont tendance à identifier les caractéristiques communes de ces comportements en deux catégories : les négatives et les positives [Kaluža et al., 2012] que le système d'identification utilisera comme variable pour déterminer le type d'un comportement selon le processus suivant :

1. Le comportement observé est **susplicieux** s'il inclut des caractéristiques **négatives** ;
2. Il est **normal** s'il contient des caractéristiques **positives** (et non négatives) ;
3. Il est alors **anormal** en l'absence de caractéristiques positives et négatives (puisque non identifié).

[Avrahami-Zilberbrand, 2009, Kaluža et al., 2012] ont opté pour ce processus au travers de la **reconnaissance de plans basée sur l'utilité** (UPR, *Utility-based Plan Recognition*) :

- Une librairie de plans hiérarchiques encode des comportements d'agents observés dans un graphe direct sur différents niveaux d'observations. UPR introduit trois types d'utilité (dont les valeurs varient en fonction du modèle de comportement, normal ou suspicieux) :

1. l'utilité séquentielle qu'un agent aurait pour aller de l'étape actuelle à une étape suivante,
2. l'utilité d'interruption de l'étape actuelle comme étant arrivée à la fin du plan,
3. l'utilité de décomposition de l'étape actuelle de ce niveau hiérarchique à sa première sous-étape au niveau inférieur.

- Une probabilité est maintenue pour chaque type d'utilité. La séquence d'observation du comportement est comparée à la librairie en utilisant un algorithme *Symbolic Plan Recognizer* qui filtre les hypothèses consistantes et les classe par leur utilité. L'hypothèse sélectionnée est celle avec le plus bas coût. Ce coût est celui envisagé si la personne est arrêtée alors qu'elle puisse être responsable ou innocente de l'événement (pris en compte selon la probabilité de suspicion) et en fonction du coût des dommages si elle n'est pas arrêtée.

- ✓ L'heuristique sur l'UPR produit une probabilité qu'un événement soit généré par une personne suspicieuse et prend en compte les dommages que provoquerait son arrestation dans le cas où elle serait responsable ou innocente. L'ajout d'une utilité permet de faire ressurgir l'identification des cas rares de comportements suspicieux dont nous ne possédons jamais assez de données pour les modéliser correctement (par rapport à l'infobésité des comportements normaux).

- ✗ Il y a une obligation de modéliser (manuellement ou par apprentissage) chaque comportement normal et suspicieux que nous désirons détecter. Il n'y a donc pas d'alerte pour les comportements anormaux. De plus, ces plans ne sont utilisables que pour l'environnement pour lequel ils ont été créés.

Pour un expert, l'approche la plus courante est l'automatisation des alertes lorsque des événements sont observés. Les traitements d'événements complexes sont particulièrement adaptés pour ce genre de solution. Lorsque les comportements attendus ont été modélisés par un modèle statistique, une fonction de distance mesure la différence entre ce qui est observé et le modèle défini. Lorsqu'un seuil est dépassé par cette distance, le système de surveillance considère que le comportement observé est déviant.

2.2.3 Traitement des événements complexes

Des comportements peuvent être modélisés en utilisant un **système expert** basé sur un ensemble de règles qui s'appliquent à des faits observés.

Pour l'identification des comportements déviants, l'exemple de système expert particulièrement adapté est le **Complex Event Processing** (CEP, "traitement des événements complexes"). Quand un événement complexe est observé sur un ensemble d'événements (et non pas de fait), des règles sont déclenchées dans le but de déterminer si celui-ci dépasse les seuils fixés (ou appris) que le comportement soit connu ou non. En fonction de l'événement identifié, des alertes sont déclenchées en fonction des paramètres spécifiques à celui-ci.

Dans un CEP, différentes notions y sont attachées et ne doivent pas être confondues :

- ◇ Un **événement** est le changement d'état d'un processus défini par le changement d'une valeur ou le dépassement d'un seuil. La notion d'événement est à différencier de la notion de fait, i.e. un **événement** est un changement d'état à un instant t alors qu'un **fait** est une représentation de ce qui se passe par un ensemble de valeurs.
- ◇ Un **événement complexe** est un événement qui ne peut se produire que si d'autres événements se produisent. Il y a trois aspects dans un événement complexe :
 - une forme : les attributs et les données qui le composent pour en faire un événement simple ou composé ;
 - une signification : la description de l'activité qu'il représente ;
 - une relativité : ses liens avec les autres événements et sa valeur temporelle.

Dans l'optique de détecter des comportements et des situations exigeant une réaction (comme une alerte de sécurité), nous avons besoin d'un ensemble de règles qui produiront les faits de haut niveau. Ces règles peuvent être de trois types :

- ◇ Les filtres donnent un sous-ensemble des événements en entrée ;
- ◇ Les agrégations produisent des événements correspondants aux causalités de ceux en entrée ;
- ◇ Les détections surveillent la présence et l'absence d'événements selon des contraintes.

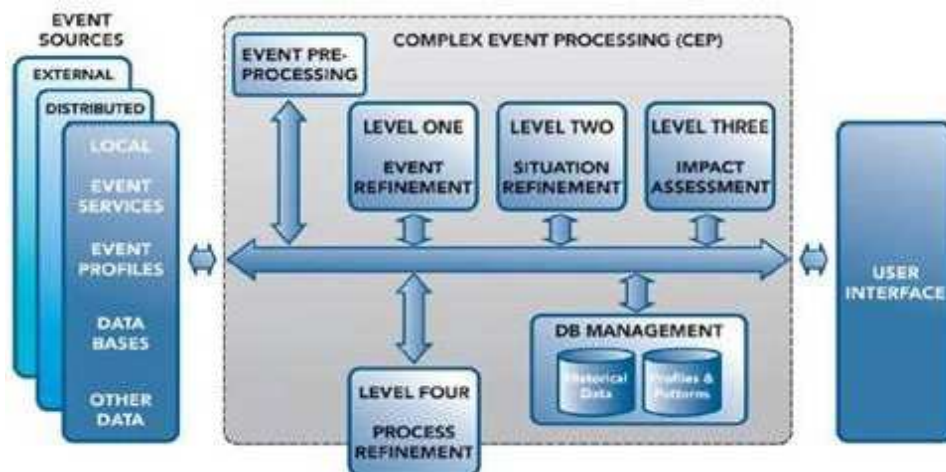


FIGURE 2.4 – Le traitement d'événements complexes sur le modèle JDL de fusion de données (Source : www.thecepblog.com)

Un nuage d'événements contient des éléments significatifs à identifier. Le premier objectif est de détecter les situations nécessitant une réaction, tels que la détection d'anomalies de comportements lorsqu'un ensemble de variables dépassent un seuil de tolérance. Ainsi le CEP se représente par les niveaux du modèle *JDL Data Fusion model* [Bowman, 2004] (Figure 2.4) et s'ordonne de la manière suivante :

- (1) le prétraitement des données pour normaliser les différentes sources ;
- (2) le filtrage des événements qui ne concernent pas le système et le déclenchement des règles simples ;
- (3) l'agrégation par les règles de nouveaux événements pour une vue globale du système (qui déclencheront de nouvelles règles) ;
- (4) une boucle retour pour la mise en œuvre des actions décidées en (3).

Ce traitement pour obtenir des événements complexes à partir de simples faits peut être interpréter comme de la fusion de données du niveau d'observation micro à méso (et macro).

Comme tout système expert, les CEP [Luckham, 2001] incluent un moteur de règles. Ce dernier fonctionne sur un (ou une hybridation) des deux algorithmes d'inférence pour exécuter les règles qui correspondent aux événements en entrée du système :

- Le **chaînage avant** (*the forward chaining*) : consiste à prendre tous les faits et les confronter à chaque règle (ordonnée selon la priorité des règles) afin de vérifier si les préconditions sont remplies. Le processus est déclenché par l'arrivée d'un ou plusieurs faits et les règles sont alors toutes exécutées pour produire de nouveaux faits.

- Le **chaînage arrière** (*the backward chaining*) : consiste à prendre toutes les conséquences des règles (ordonnées selon la priorité des conséquences) et les confronter à chaque fait afin de vérifier si les préconditions sont remplies. Le processus cherche ainsi à générer certains faits en priorité. Les langages de programmation logique (comme *Prolog*) sont basés sur ce processus.

✗ Les moteurs de règles sont rapidement saturés quand un grand volume d'événements à traiter est constamment mise à jour et répliquer par des règles de productions.

Notre première difficulté à utiliser les CEP est de fournir manuellement des règles pour obtenir des résultats de meilleure qualité. Celles-ci peuvent être extraites automatiquement comme le propose la solution *bottom-up* de [Sabouret and Sansonnet, 2001] :

- À partir d'interactions locales, les règles de comportements collectifs sont extraites et appelées **chroniques intensionnelles**. Cette intension est l'opposé de l'extension, à ne pas confondre avec l'intention. Ces chroniques sont des traces d'exécutions observées et elles sont intensionnelles car elles décrivent une interaction d'une entité envers une autre. Le processus *bottom-up* commence par extraire des comportements simples à partir des interactions locales d'un agent envers un autre, puis celles récurrentes (car souvent coopératives) envers d'autres agents et celles collectives entre tous les agents.

- ✗ Le langage VDL (*View Design Language*) permet d'écrire une règle décrivant une action selon des préconditions et une exécution. La situation y est décrite par le quintuplet $sit(a) = \langle who(a), what(a), why(a), when(a), res(a) \rangle$ dans lequel $who(a)$ référence l'acteur de l'action, $what(a)$ l'action effectuée, $why(a)$ les préconditions, $when(a)$ la date et $res(a)$ la nouvelle valeur. Les chroniques récurrentes ayant le même uplet $\langle who, what, why \rangle$ sont ensuite compactées avec une liste des $when$ et des res . Un arbre de décision est créé sur ces compactages, où les composants des uplets les plus discriminants sont dans les nœuds racines et inversement jusqu'aux feuilles.

- ✓ Les comportements observés sont continuellement appris en tant que chroniques intensionnelles. Pour identifier un comportement anormal, il suffit qu'il n'ait jamais été observé (donc non appris).

→ ¹⁹ De notre point de vue, il pourrait y avoir un compactage hiérarchique des interactions locales aux collectives pour former un arbre de décision, où la racine décrit les comportements collectifs, où les nœuds sont les chroniques intensionnelles et les branches mènent aux chroniques plus spécifiques de niveau inférieur, jusqu'aux feuilles des actions élémentaires. Les règles du plus haut niveau pourraient être compactées dans les deux catégories des comportements collectifs normaux et déviants. **Sans**

19. Le symbole "→" signifie "conclusion personnelle" et est utilisé tout au long du manuscrit.

supervision d'un expert, quand l'arbre de décision est parcouru de la racine aux feuilles pour y ajouter une nouvelle chronique intensionnelle, nous pourrions obtenir une estimation qu'il appartienne aux comportements normaux ou déviants.

✗ Un processus d'apprentissage non supervisé est un bon point puisqu'il n'oblige pas à l'intervention d'un expert pour classifier le comportement. Toutefois, en se basant sur des observations incertaines et incomplètes d'un système de surveillance, la chronique produite ne correspondra probablement pas au comportement réellement observé et sera mal classifiée dans l'arbre de décision. Alors tous les futurs comportements proches y seront rattachés, ce qui peut créer un réel biais dans l'identification des comportements normaux et déviants.

→ Un apprentissage semi-supervisé des règles est donc plus viable pour l'identification des comportements collectifs.

Le CEP est la solution intéressante pour nous permettre d'ajouter des faits (dans sa base de connaissances) que nous produisons par toutes les autres approches de détection. Par exemple, soit un ensemble d'observations (des faits de niveau **micro**) à propos des individus d'une foule surveillée. Des règles les utiliseront pour déclencher des processus d'identification des groupes. Ces processus ne sont pas obligatoirement écrits en règle pure, puisqu'elles peuvent juste déclencher des applications externes. Ces applications donneront leurs résultats sous forme d'observation de plus haut niveau (**méso**). Ces nouvelles observations pourront être réutilisées par des règles qui cherchent à identifier des comportements déviants et lancer des alertes.

Le CEP permet donc de **transférer** facilement des observations entre les différents niveaux **micro**, **méso** et **macro**, sans pour autant que les calculs de détection soient gérés par le même système. Ce dernier point est une aubaine pour **réduire les limitations hardware** provoquées par la **détection des comportements collectifs**.

2.3 Conclusion

Nous avons vu que notre étude à propos de *l'évaluation de la situation dans les environnements asymétriques avec des données incertaines et incomplètes* correspond à deux niveaux de la **fusion de données** : les relations entre les entités sont à évaluer et les comportements collectifs à anticiper.

Afin de nous concentrer sur les processus de plus haut niveau comme l'identification des groupes et des comportements déviants, nous avons évité d'étudier les approches de prétraitement des données issues des capteurs qui ont déjà fait l'objet de décennies de recherche (et des récentes solutions ont été réellement appliquées comme évoquées dans l'annexe 10 page 181). Néanmoins, le CEP (traitement d'événements complexes) est notre meilleure solution actuelle pour **identifier des comportements collectifs** (tels que les groupes et les comportements déviants). Il est en effet doté d'une certaine facilité de gestion des observations sur nos trois niveaux d'observations micro, méso et macro.

Les méthodes d'**identification** se sont révélées **seulement** utilisables dans l'environnement pour lequel elles ont été développées (tant qu'il ne subit pas de modification) et sont souvent inapplicables aux autres. C'est pourquoi, suite à cet état de l'art de détection de comportements collectifs par l'identification, nous allons maintenant le poursuivre dans les approches d'apprentissage et de reconnaissance. Celles-ci sont intéressantes pour leur réapplicabilité dans tout type d'environnement asymétrique.

"S'il a été remarqué que quelques dauphins pouvaient reconnaître jusqu'à 50 mots de notre langue, aucun humain n'a jamais pu comprendre un seul mot de la leur."

Carl Sagan

Chapitre 3

Apprentissage et Reconnaissance des Comportements

Sommaire

3.1 Premiers travaux	54
3.2 Modèle de Markov caché	55
3.2.1 Définition du HMM	55
3.2.2 Informations utiles pour la définition des états	57
3.2.3 Récapitulatif des extensions du HMM	58
3.3 Décomposition de l'espace des paramètres	63
A. Décomposition par la discrétisation des états	63
B. Décomposition des observations	63
C. Décomposition en couches	64
D. Décomposition et agrégation des informations	65
E. Conclusion pour la décomposition des comportements simples	66
3.4 Hiérarchisation des comportements	66
I. Hiérarchie à base de grammaires stochastiques	67
II. Hiérarchie à base de décisions stochastiques hiérarchisées	68
III. Hiérarchie adaptée au groupe d'agents	69
IV. Hiérarchie factorisée pour réduire l'explosion du nombre d'états	70
V. Hiérarchie adaptée pour les séquences d'activités à long terme	71
VI. Hiérarchie adaptée au système multi-agent	71
VII. Conclusion pour la hiérarchisation des comportements abstraits	72

Au sujet des approches de détection de comportements collectifs, l'état de l'art est **principalement constitué** de modèles qui permettent de les représenter par une méthode d'**apprentissage** et d'une méthode de **reconnaissance**, en temps réel ou non (obligeant alors l'utilisation de méthodes approximatives pour y parvenir).

Les comportements individuels sont rarement simples et les actions collectives encore moins. Face à cette complexité, la communauté scientifique a utilisé une parade : les modèles **décomposent** les comportements en une **séquence d'états**. De nos jours, différents algorithmes sont constamment utilisés

pour **apprendre** et **reconnaître** ces séquences dans des modèles. Ces modèles se basent sur un ensemble d'états, où chaque **état** caractérise une possibilité de ce que le monde peut être. Un modèle de comportement peut ainsi le représenter de manière **séquentiellement** décomposée et **parallèlement** sur différents niveaux d'observations (micro, méso et macro). Les algorithmes prennent en compte l'**incertitude** et l'**incomplétude des observations** pour une meilleure qualité de reconnaissance et d'apprentissage.

3.1 Premiers travaux

Les plus anciens travaux de ce sujet ont déterminé ce que sont devenues les méthodes Markoviennes actuellement utilisées par les experts de ce domaine.

L'approche élémentaire consiste à transiter d'un état au suivant pour chaque événement observé jusqu'à atteindre un état final qui indique un comportement précis :

- Les *Nondeterministic Finite Automaton* (NFA) [Wada and Matsuyama, 1998] et les *Finite State Machine* (FSM) [Ayers and Shah, 2001] reconnaissent un comportement simple de manière équivalente : un état peut transiter vers une multitude d'états et seul l'événement observé produit une transition vers l'un d'eux.

✓ [Wada and Matsuyama, 1998, Ayers and Shah, 2001] les ont récemment réutilisés pour tester leur système d'analyse vidéo qui extrait les multiples entités de la situation et en produit des observations. Ce sont les premières approches de reconnaissance d'activités simples qui ont défini un comportement par la **décomposition en une séquence d'événements simples**.

✗ Pour un NFA, les états indiquent directement chaque action observée par la position de l'entité (e.g. "être proche de la machine à café" signifie "prendre un café"). La séquence d'actions n'indique pas le comportement.

✗ Pour un FSM, il faut atteindre un état final pour reconnaître un comportement, alors qu'un comportement peut transiter par une longue séquence d'états intermédiaires.

✗ Les états sont définis à la main sans méthode d'apprentissage. L'incertitude et l'incomplétude des observations (obtenues des capteurs) ne sont pas prises en compte dans la reconnaissance. Les états du graphe direct ne sont pas tous reliés par paire, il n'y a donc pas la possibilité d'aller dans un état inattendu.

Des approches à base de graphes et d'arbres probabilistes ont vu le jour pour modéliser les contraintes temporelles des actions et des événements.

- Afin d'encoder les relations entre les observations d'un comportement, le *Hierarchical Conditional Random Field* [Liao et al., 2007, Vail et al., 2007] encode directement une distribution conditionnelle par apprentissage. De même, l'apprentissage par renforcement inversé (*Inverse Reinforcement Learning*, IRL) [Choi and Kim, 2009] décrit l'intention / l'objectif / le comportement de chaque agent en cherchant à reproduire la fonction de récompense qui a amené un agent à exécuter sa politique observée.

✗ Cependant ces techniques souffrent d'un besoin significatif en temps et en données d'observations pour l'apprentissage du comportement d'un agent exécutant des séquences d'actions primitives. Cette difficulté sera encore plus importante si nous adaptons ces techniques aux comportements collectifs.

- En représentant les liens entre événements et actions avec une contrainte d'ordre partiel, la reconnaissance d'activités [Charniak Robert et al., 1993, Shi et al., 2004] dans un réseau Bayésien s'effectue par inférence stochastique. Dans ce genre de représentation, **la planification et la détection des**

comportements ont une seule différence : la direction de la propagation de l'information comme dans un réseau Bayésien dynamique (DBN, *Dynamic Bayesian Networks*) [Giersich et al., 2007] qui la propage dans les deux sens (par l'inférence) et modélise l'influence du temps (par une séquence d'états ordonnés). Ceci est résolu par un algorithme qui calcule les probabilités postérieures sur une distribution des interprétations disponibles. C'est exactement ce que produit l'algorithme de *Viterbi* qui a été développé principalement pour le modèle représentatif de ce chapitre : le **modèle de Markov caché**.

De nos jours, ces premiers travaux sont utilisés comme un moyen de comparaison simple aux nouvelles approches, notamment aux méthodes d'extractions de données issues des signaux de capteurs.

3.2 Modèle de Markov caché

Ce qu'est la recherche scientifique en **reconnaissance** à celle de la **planification**, représente ce qu'est le **Modèle de Markov Caché** au **Processus Décisionnel de Markov** (MDP). Tout comme le MDP, le modèle de Markov caché a été tout autant étendu et complexifié en différentes versions pour contrer les limites rencontrées.

3.2.1 Définition du HMM

Ce qui a retenu particulièrement notre attention est le **modèle de Markov caché** (*Hidden Markov Model* noté **HMM**) qui, de nos jours, possède de multiples extensions (que nous présenterons) pour des applications dans divers domaines dont l'objectif est la reconnaissance : des gestes, de la démarche, des activités, de l'écriture, de la météo,...

Il permet en effet de **représenter** un système défini (e.g. un comportement) sur un ensemble d'états cachés (définis et reconnus à partir d'informations partiellement observables), où une distribution de probabilités de transition (entre ses états) peut être apprise sur un ensemble de séquences d'observation (d'un même comportement). En d'autres termes, un HMM est utile pour représenter un comportement et la Figure 3.1(b) nous montre qu'il est facilement représenté comme un réseau Bayésien dynamique (DBN).

Nous adoptons la **définition du HMM** [Rabiner and Juang, 1986] par le 5-uplet $\langle Q, A, O, B, \Pi \rangle$:

Q est un ensemble fini d'états cachés, où q_i est le $i^{\text{ème}}$ état caché ;

A est un ensemble fini de probabilités de transitions, où $a_{ij} = Pr(s_{t+1} = q_j | s_t = q_i)$ est la probabilité de transition que l'état caché sera q_j après q_i ;

O est un ensemble fini d'états observables, où o_i est l'état partiellement observable de q_i ;

B est un ensemble fini de probabilités d'observation, où $b_{ik} = Pr(o_k | q_i)$ est la probabilité d'observer o_k pendant l'état q_i ;

Π est un ensemble fini de probabilités d'états initiaux, où $\pi_i = Pr(s_0 = q_i)$ est la probabilité d'être initialement dans l'état q_i .

Ses contraintes sont :

$\forall i \in Q, \sum_{j=1}^{|Q|} a_{ij} = 1$: La somme des probabilités de transition partant d'un état caché est égale à un ;

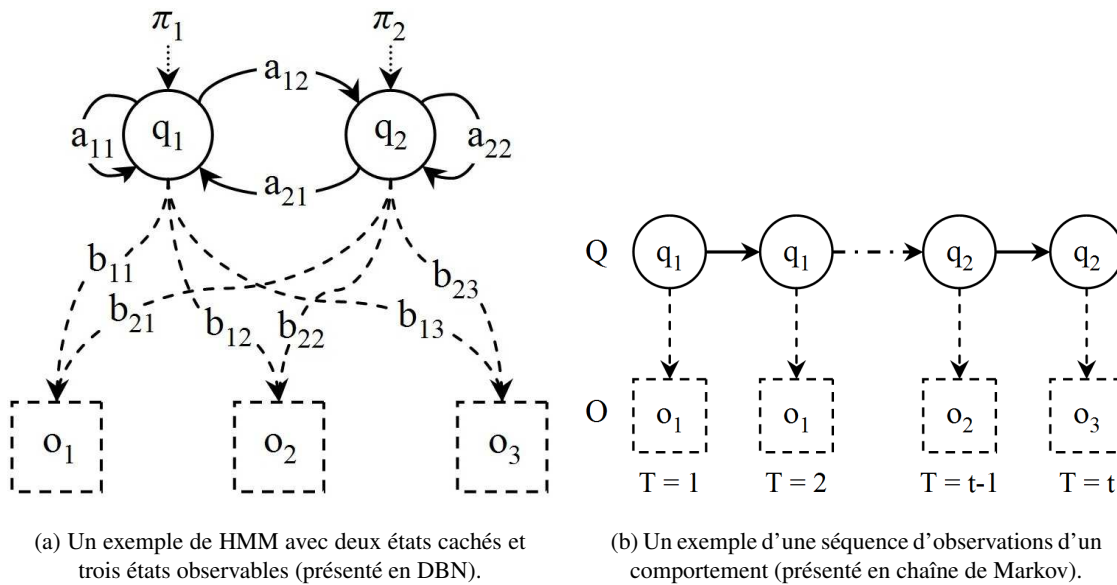


FIGURE 3.1 – Un HMM.

$\forall i \in Q, \sum_{k=1}^{|Q|} b_{ik} = 1$: La somme des probabilités d'observation sur un état caché est égale à un ;

$\sum_{i=0}^{|Q|} \pi_i = 1$: La somme des probabilités d'états initiaux est égale à un.

Trois calculs principaux existent sur un HMM [Rabiner and Juang, 1986] :

1. La probabilité qu'un état caché s_t soit l'état actuel se calcule par l'équation $Pr(s_t = q_t | O_t)$. Nous pouvons en extraire l'état caché le plus probable q_t à l'étape t sachant une séquence d'observations $O_t = \{o_1, \dots, o_t\}$. Ceci est résolu par un algorithme de programmation dynamique tel que *Forward-Backward* [Rabiner, 1989] ;
2. L'algorithme *Viterbi* [Rabiner, 1989] donne la séquence d'états cachés la plus probable sachant une séquence d'observations ;
3. L'apprentissage d'un HMM est réalisable par l'algorithme de *Baum-Welch* [Rabiner, 1989] qui utilise la méthode *Expectation-Maximization*. Il a pour objectif de calculer une probabilité maximum pour une séquence qui faisait partie de celles qui ont été apprises.

Un avantage non négligeable d'un HMM est qu'il respecte l'**hypothèse de Markov**. Une **propriété de Markov à l'ordre k** satisfaite implique que les probabilités de transitions dépendent seulement des k états précédents. Nous en obtenons ainsi une **chaîne Markovienne de premier ordre** avec des états non directement observables (internes aux agents). En supplément, afin d'obtenir une évaluation de la situation à partir d'observations, nous pouvons y appliquer des méthodes liées à l'**inférence Bayésienne** pour gérer l'incertitude et l'incomplétude des informations.

Le **HMM** est le modèle le plus utilisé et modifié dans le domaine de la reconnaissance. En effet, ce modèle *Markovien* a obtenu autant d'extensions que le **MDP** (*Markov Decision Process*, i.e. un **Processus Décisionnel de Markov**) pour trouver de nouvelles solutions pour la reconnaissance des

comportements. Ces solutions tentent de contourner les limites rencontrées dans l'apprentissage et la reconnaissance : des formations, des rôles, des actions, des activités, des plans, des politiques, des objectifs, des intentions,... appliqués du niveau d'observation **micro** (pour chaque entité) jusqu'au **macro** (pour la foule) en passant par **méso** (pour les groupes), sur des environnements simples aux complexes (tels qu'**asymétriques**) et souvent dynamique.

La qualité des résultats de reconnaissance et d'apprentissage de comportements distincts par un modèle est directement liée à l'ensemble des états du modèle, quel que soit le type de modèle tant qu'il décompose un comportement en une séquence d'états. C'est pour cette raison que nous devons déterminer de quoi un état doit être composé.

3.2.2 Informations utiles pour la définition des états

La définition des états nous donne la base des comportements qui peuvent être séquencés, appris et reconnus. Les avantages et les limites de ces modèles sont directement liés aux types d'informations présents dans les états du modèle.

Les méthodes de reconnaissance dépendent des comportements à reconnaître [Han and Veloso, 2000], généralement classés en trois types de catégories :

▷ **"Absolute position"** : Ces approches segmentent l'environnement en régions distinctes qui représentent chacune d'elle en un état possible. La position $\langle x, y, \theta \rangle$ d'une entité observée permet de savoir quel est son état. Ainsi les comportements qui peuvent être facilement appris et reconnus sont directement corrélés aux **déplacements** des agents (comme dans [Wada and Matsuyama, 1998, Ayers and Shah, 2001]).

Plus l'environnement est **dynamique**, plus la qualité des résultats de reconnaissance **diminue**. Par exemple, si nous définissons l'ensemble d'états pour chaque position absolue de la zone surveillée, alors un comportement de mouvement est décrit par une séquence d'états. À chaque modification de l'environnement, les états et/ou les séquences peuvent en être modifiés, ce qui en affectera leur reconnaissance. Ainsi pour chaque comportement à reconnaître, les séquences à apprendre doivent être mises à jour à chacune des modifications de l'environnement. L'obtention de ses séquences d'observations est déjà suffisamment difficile quand il n'y a pas de modification.

▷ **"Object relative"** : Une information relative d'une entité observée par rapport à une autre est utilisée, telle que la position relative (la distance). Nous y retrouvons notamment les méthodes couplant les informations comme celles basées sur le HMM ([Oliver et al., 2000, Gong and Xiang, 2003], section "Décomposition en couches" page 64) et d'autres utilisant des ontologies pour décrire les interactions possibles avec les autres entités de l'environnement ([Gaitanis et al.,], section "Hiérarchie adaptée au système multi-agent" page 71).

▷ **"Dynamic"** : Les propriétés dynamiques des entités sont utilisées. Ces approches ne s'appuient pas seulement sur les caractéristiques observables des entités, mais elles se basent surtout sur les **actions observables** des entités. Chaque entité identifiée dispose de propriétés dynamiques qui sont modifiées par des actions. Le système s'attend à observer ses actions et à les reconnaître facilement. Comme exemple, un individu marche à une vitesse constante puis accélère jusqu'à une nouvelle vitesse constante, alors la propriété dynamique de cette variable nous indique que l'individu s'est mis à courir. C'est le parfait exemple de l'utilisation d'un CEP (section "Traitement des événements complexes" page 49).

À propos des informations utiles à la définition d'un état, nous pouvons déduire la même chose qu'à propos de la modélisation des groupes par un centroïde (section "[Centroïde, une modélisation de groupe](#)" page 47) : les états doivent inclure les informations minimales à propos des caractéristiques extraites des comportements. Toute caractéristique peut être **discrétisée** selon son type (agent, groupe, environnement) et/ou leurs relations avec les autres entités. Par exemple, la position peut se discrétiser en découpant la carte de l'environnement en zones et la vitesse selon l'action effectuée ("l'entité est stoppée, en train de marcher ou de courir"). La **discrétisation** des variables continues nous permet de **réduire l'espace des paramètres** et donc le nombre d'états. Lors de l'apprentissage de séquences d'états d'un comportement observé, un nombre minimal d'états permet que chaque transition d'état soit plus souvent **visitée**. Au vu de la **difficulté** d'obtenir une grande quantité d'**observations** de bonne qualité (sans incertitude et sans incomplétude) de chaque comportement à apprendre et à reconnaître, c'est un avantage que soit réduit le nombre de séquences requis.

Attention toutefois, un modèle peut apprendre un **ensemble de comportements distincts** sur le même ensemble d'états, mais chacun des modèles appris possède **ses propres probabilités de transitions** d'états à états. Si ce nombre d'états est trop réduit, alors des comportements distincts risquent d'être **décomposés par des séquences d'états communes**. Lorsque le système de reconnaissance observe une séquence commune, le modèle sélectionné est toujours celui ayant appris le plus de fois cette séquence. Chaque fois que cette séquence commune correspond au modèle non sélectionné, il y a une **fausse reconnaissance**. Pour la simple raison que les informations minimales exigées dans un état **n'ont pas été correctement définies** dès le départ, notre seul moyen d'augmenter la qualité des résultats des détections des comportements est : soit de **fusionner** les comportements distincts ayant des séquences communes, soit de **supprimer** ces séquences communes de l'apprentissage. L'une ou l'autre nous semble être **une solution approximative** (que cet apprentissage soit appliqué de manière automatique ou semi-supervisée). Selon les comportements que nous cherchons à détecter, l'ensemble des états doit donc être **défini avec les informations minimales** qui nous permettent de **réduire la complexité** de l'apprentissage et de la reconnaissance, tout en permettant que les comportements distincts **ne se chevauchent pas** dans les modèles appris.

Dans la suite de ce chapitre, nous présentons différentes manières de définir des états qui ont eu un fort impact sur les extensions de HMM appliquées à l'apprentissage et la reconnaissance de comportements. La sous-section suivante récapitule les schémas de ces extensions.

3.2.3 Récapitulatif des extensions du HMM

En comparant les divers schémas de la littérature scientifique, il est simple de constater que les extensions du HMM (appliquées à la reconnaissance des comportements collectifs) ont été complexifiées. Cette **évolution** a permis d'offrir une solution passant de la détection des comportements de simples activités d'un agent (**micro**) à celle des comportements multi-objectifs des systèmes multi-agents (**macro**). C'est pourquoi avant d'expliquer cette évolution dans tout le reste du chapitre, nous présentons leurs schémas respectifs.

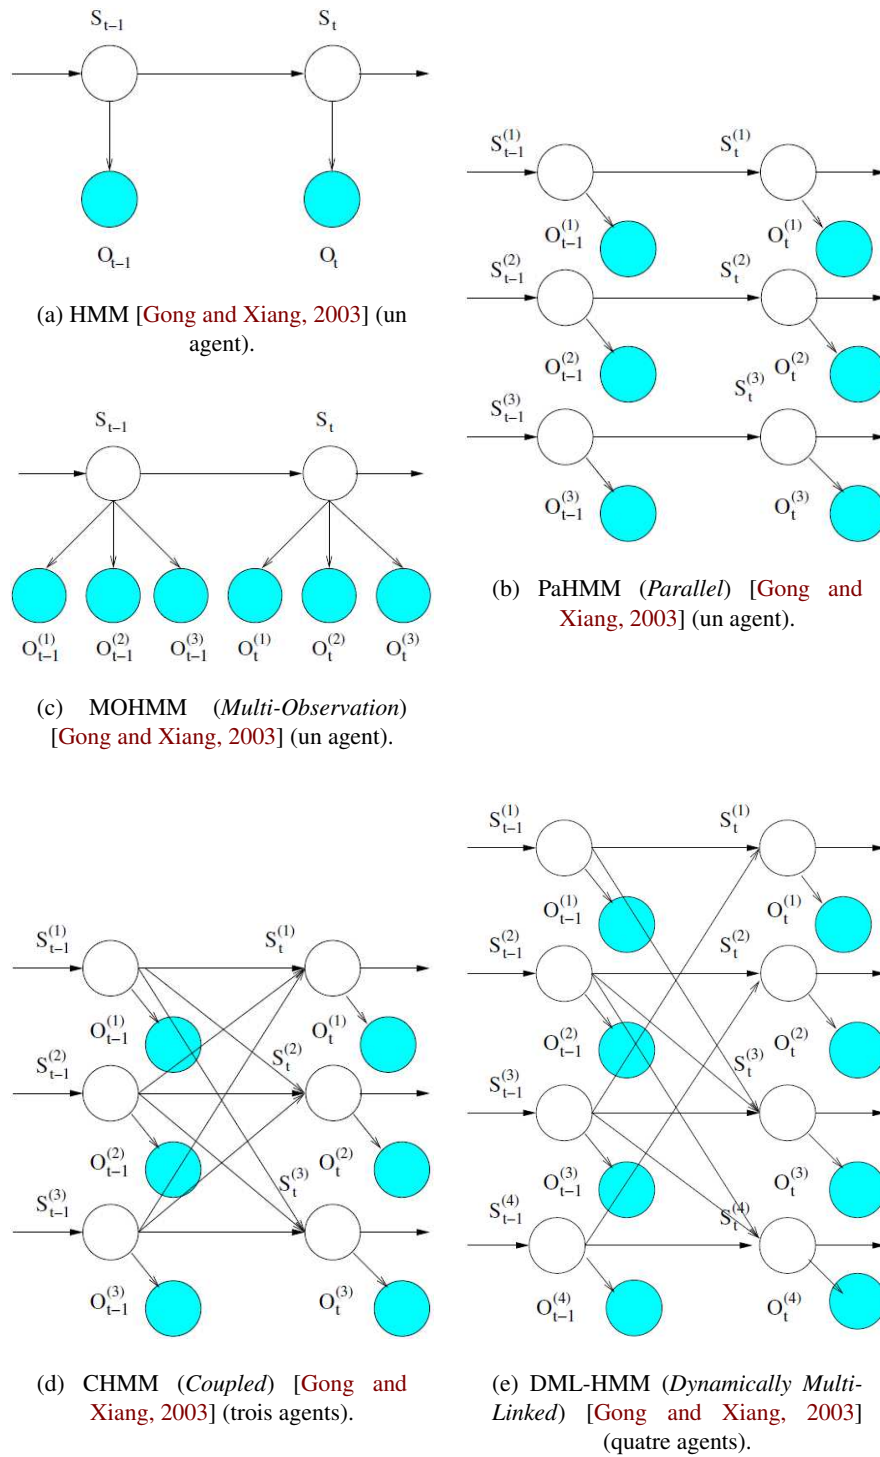





FIGURE 3.2 – Les différentes approches pour la modélisation de comportements simples à titre de comparaison de leur complexité [Gong and Xiang, 2003]




(f) FHMM (*Factorial*) [Oliver et al., 2000] (un agent).




(g) HMDT (*Hidden Markov Decision Trees*) [Oliver et al., 2000] (un agent).




(h) LHMM (*Linked*) [Oliver et al., 2000] (deux agents).



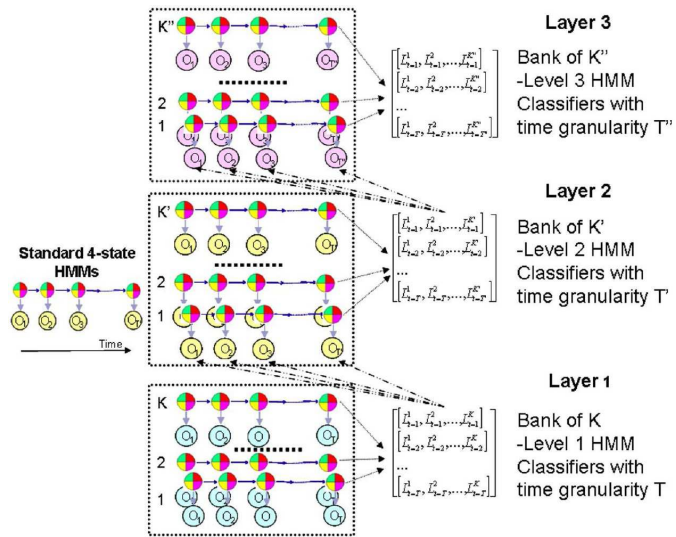
(i) CHMM (*Coupled*) [Oliver et al., 2000] (deux agents).



(j) ODHMM (*Observation Decomposed*) [Liu and Chua, 2003] (trois agents).

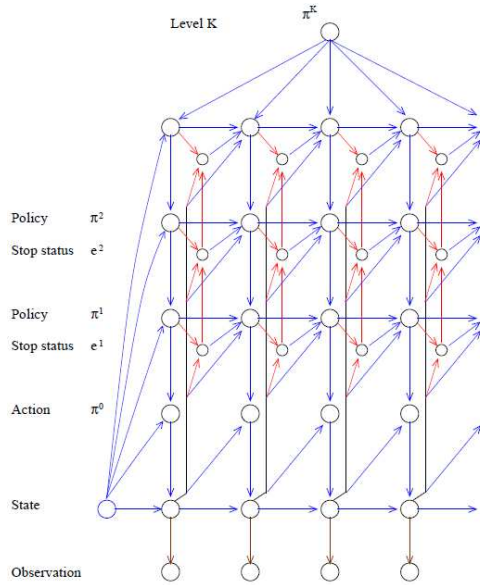


(l) BHMM (*Behavioral*) [Han and Veloso, 2000] (un agent).

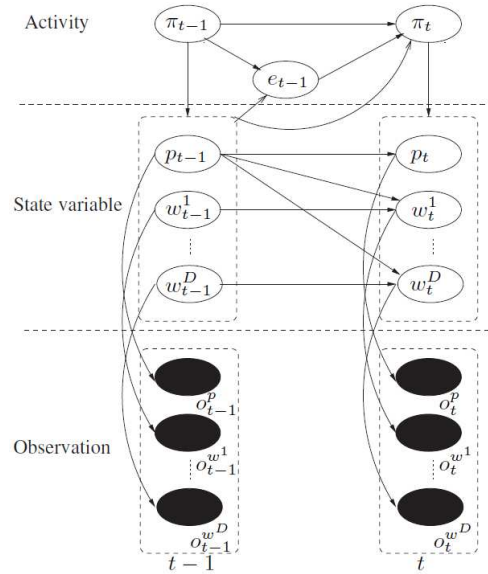


(k) LHMM (*Layered*) [Oliver et al., 2002] (un agent).


FIGURE 3.3 – Les différentes approches pour la modélisation de comportements simples à titre de comparaison de leur complexité [Han and Veloso, 2000, Liu and Chua, 2003, Oliver et al., 2000, Oliver et al., 2002].



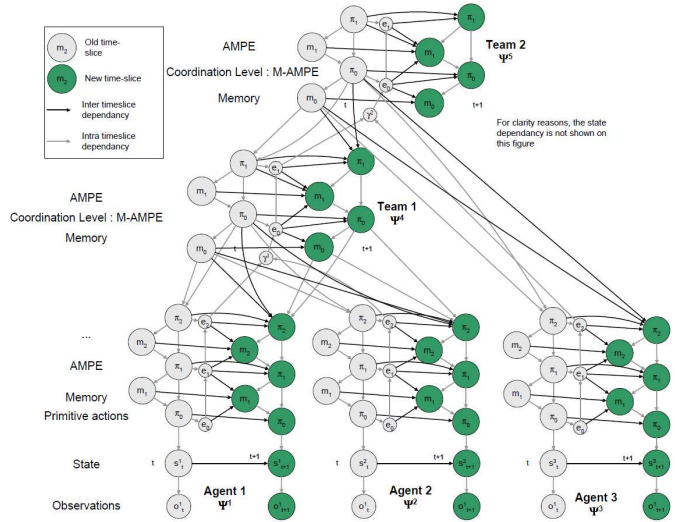
(m) AHMM (Abstract) [Bui et al., 2002] (un agent).



(n) FS-AHMM (Factorised State) [Tran et al., 2005] (un agent).

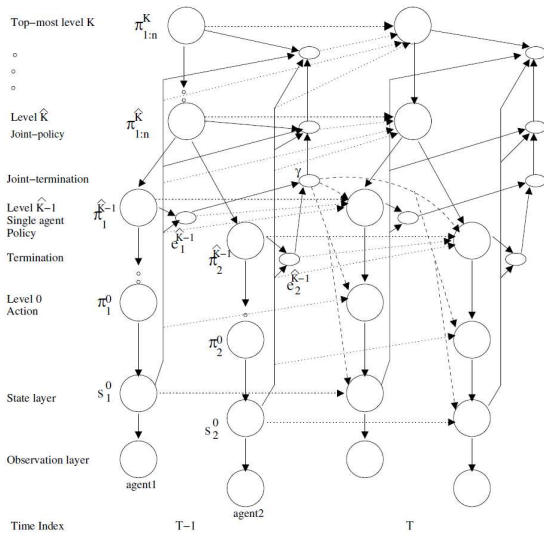


(o) AHMEM (with mEmory) [Bui, 2002] (incluant deux AHMEM d'un agent).




(p) M-AHMEM (Multi-agent) [Gaitanis and Macq, 2008] (incluant trois AHMEM d'agents appartenant à deux groupes).


FIGURE 3.4 – Les différentes approches pour la modélisation de comportements abstraits à titre de comparaison de leur complexité [Bui et al., 2002, Bui, 2002, Gaitanis and Macq, 2008, Tran et al., 2005].



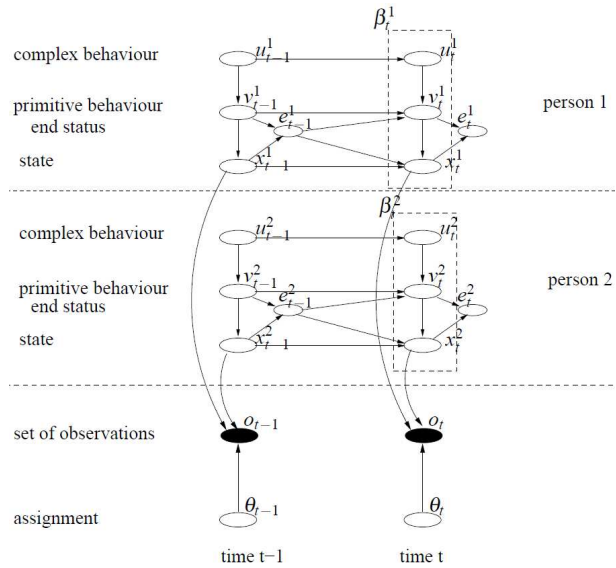
(q) HMMP (*Hierarchical Multiagent Markov Process*) [Saria and Mahadevan, 2004] (incluant deux AHMM d'agents).



(r) HHMM (*Hierarchical*) [Bui et al., 2004] (un agent).



(s) S-HSMM (*Switching Hidden Semi-Markov Model*) [Duong et al., 2005] (un agent).



(t) HHMM-JPDAF (*Joint Probabilistic Data Association Filters*) [Nguyen et al., 2005] (incluant deux HHMM d'agents).

FIGURE 3.5 – Les différentes approches pour la modélisation de comportements hiérarchisés à titre de comparaison de leur complexité [Bui et al., 2004, Duong et al., 2005, Nguyen et al., 2005, Saria and Mahadevan, 2004].

La sous-section suivante présente notre état de l'art des approches de décomposition qui ont, chaque fois, produit une nouvelle extension du HMM (ainsi que pour les autres modèles séquençant les comportements pour les détecter). Chaque extension se rapporte à un schéma présenté dans la cette sous-section.

3.3 Décomposition de l'espace des paramètres

La décomposition de l'espace des paramètres est la méthode la plus utilisée pour réduire la complexité du problème d'apprentissage et de reconnaissance. Cependant, nous allons voir que cette décomposition requiert un coût additionnel en données et en temps d'exécution puisque la séquence est continue et doit donc être segmentée et classifiée à intervalles réguliers, quelle que soit la manière de décomposer :

- A. par la discrétisation des états,
- B. les observations,
- C. en différentes couches,
- D. pour ensuite recouper les informations.

A. Décomposition par la discrétisation des états

La décomposition de l'espace des paramètres consiste à créer un ensemble d'états finis dans lequel une entité peut être observée. Une séquence d'états représente un comportement observé.

• Nous retrouvons ce concept dans le *Behavior Hidden Markov Model* (BHMM, Figure 3.3(1) page 60) [Han and Veloso, 2000] qui décompose en quatre étapes les comportements d'agents :

1. "Initial states" : les états où l'agent serait au départ de l'exécution d'un comportement ;
2. "Accept states" : les états qui servent de signal pour une détection réussie d'un comportement achevé ;
3. "Intermediate states" : les états traversés pour atteindre les états acceptés ;
4. "Reject states" : un système de reconnaissance naïve de comportements donnera un résultat ambigu quand l'observation en entrée n'a pas été générée par son comportement, il y est alors inclus les autres comportements.

✗ Le BHMM suppose que chaque comportement commence à l'état initial et se complète à l'état accepté. La séquence continue doit donc être segmentée à intervalles réguliers sur différentes longueurs. La reconnaissance de chaque segment doit être testée. Ces deux derniers faits augmentent fortement le nombre de calculs. Tant que l'agent est observé dans un état intermédiaire, il n'y a pas de comportement détecté.

B. Décomposition des observations

Certaines approches ont privilégié la décomposition des états observables plutôt que celle des états cachés. L'idée est d'éviter le risque que l'incomplétude et l'incertitude d'une observation amènent à sélectionner un état caché (parmi les plus probables) qui ne correspond pas à l'état observé.

La décomposition des observations dans les HMM a eu une adaptation des comportements simples d'agents aux activités collectives d'agents :

- Le *Multi-Observation Hidden Markov Model* (MOHMM, Figure 3.2(c) page 59) [Gong and Xiang, 2003] s'applique aux comportements d'un agent simple et décompose une observation en chaque caractéristique individuelle (inclut dans une sous-observation). Chaque ensemble de sous observations est relié à un seul état caché.

- Cette idée a été adaptée pour modéliser les activités multi-agents dans le *Observation Decomposed Hidden Markov Model* (ODHMM, Figure 3.3(j) page 60) [Liu and Chua, 2003]. Chaque observation d'un agent est décomposée de la même manière, mais l'ODHMM associe l'ensemble des sous-observations (de tous les agents effectuant l'action collective) à un seul état caché multi-agents. Au lieu d'un vecteur d'observation ayant une seule grande dimension, un ensemble de vecteurs d'observation ayant une petite dimension est utilisé.

✓ Dans le cas de la détection de comportements simples d'un agent, l'ensemble des sous-observations réduit le besoin en mémoire qu'aurait occupé chaque observation possible. Les caractéristiques prises individuellement permettent de diminuer le risque que le système sélectionne un autre état caché que celui observé.

✗ Dans le cas multi-agents, le grand nombre de sous-observations pour chaque sous-agent augmente considérablement le besoin en mémoire. Cette limite est la même que rencontrée précédemment dans la section "**Reconnaissance d'équipe**" page 45 (i.e. la décomposition des activités d'équipe selon chaque possible nombre et rôle des membres) : pour chaque comportement et pour chaque agent, chaque sous-observation possible doit être modélisée. Ceci requiert une plus grande quantité de comportements observés afin que chaque sous-observation soit rencontrée un minimum de fois lors de l'apprentissage.

- Au lieu de jouer sur la manière de décomposer les observations, [Galata et al., 2001] propose d'optimiser localement la taille de la mémoire des comportements. Pour cela, un *Variable Length Markov Model* (VLMM) utilise une mesure *cross entropy* lors de l'apprentissage des dépendances et des contraintes comportementales. Nous avons à faire ici à **une première méthode approximative** qui permet son utilisation en temps réel.

→ Une nouvelle limite au HMM est apparue dans cette sous-section : dans le cas où une séquence d'observations d'un comportement inclut une transition d'états jamais rencontrée lors de l'apprentissage du modèle du comportement, alors l'**algorithme de reconnaissance répondra par une probabilité nulle** que le modèle observé soit celui pourtant appris. Afin d'éviter ce problème, **tout modèle vierge** (i.e. avant apprentissage) doit avoir une **probabilité égale** (donc non nulle) d'aller d'un état à tout autre état. Ainsi l'algorithme d'apprentissage, qui "met à jour" la probabilité pour les séquences d'états les plus récurrentes, produira un modèle dont l'algorithme de reconnaissance ne répondra jamais une probabilité nulle (mais pouvant être infinitésimalement faible).

C. Décomposition en couches

Un principe de décomposition consiste à modéliser un comportement sur plusieurs couches.

Chaque couche d'un *Layered Hidden Markov Model* (LHMM, Figure 3.3(k) page 60) [Oliver et al., 2002] est un HMM du même comportement, mais sur un niveau de granularité temporelle différent et/ou une source d'information distincte (i.e. issue d'un type de capteur distinct tel que vidéo, sonore, infra-rouge, sismomètre,...).

- Un niveau de granularité temporelle définit le laps de temps entre chaque nouvelle observation de la situation. La classification du comportement peut être effectuée selon un critère tel que *maxbelief*

(i.e. le modèle de comportement sélectionné est celui ayant la plus haute probabilité sur chacune des couches).

✓ Un même comportement est donc modélisé de manière plus représentative malgré la variabilité des activités humaines.

✗ Les n couches requièrent au maximum n fois plus de mémoire. Cette limite réduit l'efficacité de son utilisation en temps réel, surtout si le nombre de modèles de comportements et le nombre de couches augmentent.

→ Si nous considérons chaque couche comme une source traitée indépendamment selon son type et son origine, qui est ensuite fusionnée avec les autres pour une meilleure qualité d'évaluation de la situation, alors ce modèle étendu du HMM fonctionne sur le même principe que le prétraitement (niveau 0) de la fusion de données (section "[Modèle JDL de fusion de données](#)" page 38).

D. Décomposition et agrégation des informations

La décomposition est un processus utile pour réduire la complexité d'un modèle de comportement, mais le recoupage des informations décomposées pour n'en garder que les informations utiles à l'apprentissage et à la reconnaissance permettent aussi de réduire cette complexité.

- Nous pouvons prendre l'exemple du *Coupled Hidden Markov Model* (CHMM, Figure 3.3(i) page 60) [Oliver et al., 2000] pour la modélisation de **deux comportements en interaction** l'un avec l'autre. Ce modèle utilise deux *chaînes de Markov* (une par individu) couplées avec des matrices de probabilités conditionnelles modélisant les influences (temporelles) causales. Chaque entité détectée en mouvement est ainsi décrite par un vecteur de caractéristiques (son mouvement et ses relations avec ses objets voisins) servant d'états stochastiques.

✓ Ce modèle étendu du HMM permet de détecter des comportements d'interactions entre deux agents. Les comportements d'interactions entre deux agents sont à considérer comme **le plus bas niveau** d'un comportement collectif (exigeant plus de deux agents).

✗ La librairie d'un HMM inclut n interactions de comportements, mais celle d'un CHMM doit en posséder $n \times n$ pour modéliser chaque paire possible entre deux individus. Retrouver le comportement observé le plus proche parmi celles d'une liste apprise comporte déjà quelques risques avec les comportements qui se chevauchent (i.e. qui sont proches stochastiquement sur les séquences d'états), et cette approche qui augmente leur nombre ne peut qu'amplifier le risque d'erreur.

- Cette dernière idée a été adaptée pour passer de la modélisation d'interactions par paire d'individus à celle d'**interactions de groupe** : le *Dynamically Multi-Linked Hidden Markov Model* (DML-HMM, Figure 3.2(e) page 59) [Gong and Xiang, 2003] cherche à découvrir les liens dynamiques fondamentaux parmi des événements temporels multiples en utilisant les *Dynamic Probabilistic Networks* (DPN). Un DML-HMM est appris en utilisant la factorisation basée sur le *Schwarz's Bayesian Information Criterion*. Un objet "événement" est représenté par un vecteur de caractéristiques multidimensionnel et est classifié en utilisant des *Gaussian Mixture Models*.

✓ Le DML-HMM **fusionne les approches** des trois précédents modèles basés sur le HMM :

1. Le CHMM (*Coupled Hidden Markov Model*, Figure 3.2(d)) modélise les influences temporelles causales ;
2. Le MOHMM (*Multi-Observation Hidden Markov Model*, Figure 3.2(c)) décompose en observation multiple pour un même état ;

3. Le PaHMM (*Parallel Hidden Markov Model*, Figure 3.2(b)) factorise l'espace des états en multiples processus temporels indépendants. La reconnaissance fonctionne comme un **algorithme anytime** : la **parallélisation** permet une reconnaissance dès la première observation et sa qualité s'améliore avec les résultats suivants.

→ Cette approche de décomposition et de recombinaison nous **prouve la possibilité de fusionner différentes approches** afin d'en combiner certains avantages et de contourner certaines limites rencontrées. Ce fait est la base de toutes les prochaines extensions du HMM.

E. Conclusion pour la décomposition des comportements simples

La reconnaissance des comportements simples (tels que l'activité d'un ou plusieurs agents) peut s'effectuer par la décomposition de l'espace des paramètres, mais notre cas d'étude est celui des comportements collectifs, sous-entendu "complexes".

La décomposition offre une manière simple de modéliser un comportement, mais son principal défaut est son besoin supplémentaire en ressource. Les travaux scientifiques présentés dans cette sous-section interpellent sur le fait que la complexité d'un HMM augmente exponentiellement avec le nombre d'agents. Cette information nous rend déjà compte de la difficulté d'adapter aux comportements collectifs, les méthodes s'appuyant sur la décomposition. De plus, un comportement collectif est de manière générale :

- ▷ **complexe** : chaque individu peut exécuter une variabilité d'actions séquentiellement et parallèlement aux autres membres du collectif ;
- ▷ **abstrait** : il faut observer sur le long terme, les activités collectives pour comprendre le comportement collectif actuel. Par exemple, dans un mouvement de foule, les individus adoptent souvent celui de la foule quand l'objectif est le même, ceci sans forcément produire la meilleure solution collective pour l'atteindre.

Afin de modéliser de tels comportements collectifs, les approches ont été développées en utilisant une **décomposition hiérarchique** sur différents niveaux d'observation.

3.4 Hiérarchisation des comportements

Là où un comportement simple se décompose séquentiellement en états, un comportement complexe se décompose parallèlement en différents niveaux d'observation. Ce procédé est la **hiérarchisation** du comportement par sa modélisation sur différents **niveaux** : les plus bas niveaux représentent les actions individuelles à très court terme, les moyens niveaux pour les activités collectives à moyen terme et les plus hauts niveaux pour l'intention collective à long terme. Nous retrouvons ici une corrélation au concept des niveaux d'observation de la situation (micro, méso, macro).

Différentes extensions du HMM ont été produites afin d'inclure une inférence de haut niveau et une gestion de l'incertitude. Pour la hiérarchisation des comportements, les modèles ont évolué de manière séquentielle et en parallèle :

- I. en se réappropriant les modèles de grammaire stochastiques (i.e. une approche différente, mais corrélée au HMM pour l'apprentissage et la reconnaissance de comportements) ;
- II. puis de même avec les modèles de décision stochastique hiérarchisée (adaptés des modèles de plans et/ou de politiques du domaine de la planification) ;

- III. ce qui a été adapté pour un ensemble d'agents ;
- IV. mais l'explosion du nombre d'états a obligé à chercher des solutions comme la factorisation ;
- V. et l'ajout d'une mémoire des activités déjà effectuées permet une modélisation à long terme ;
- VI. pour finalement être adapté pour l'approche multi-agents.

I. Hiérarchie à base de grammaires stochastiques

Dans le domaine du **traitement automatique des langues**, des approches ont été développées afin de modéliser les langages écrits et verbaux. Les phrases se décomposent en séquences de mots, tout comme les comportements se décomposent en séquence d'états. Les approches concernant les **grammaires stochastiques** ont notamment été adaptées à notre étude. Il s'agit aussi d'une approche (autre que le HMM) qui décompose un comportement afin d'être capable de l'apprendre et le reconnaître.

Une **grammaire d'activité** (*Context-Free Grammar*) [Kitani et al., 2006] définit un comportement sur le procédé suivant :

- Chaque action (*primitive*) possible correspond à un symbole du plus bas niveau (e.g. a, b, c, d, \dots) ;
- Chaque activité possible correspond à un symbole de haut niveau (e.g. A, B, C, \dots) et se décompose en une (ou plusieurs) séquence(s) d'activité et / ou d'actions (e.g. " $A \rightarrow a + b$ ", " $A \rightarrow a + c$ ", " $B \rightarrow a + d$ ", " $C \rightarrow B + d$ ", ...).
- Un comportement S se définit sur un ensemble de règles de production (e.g. " $S \rightarrow A$ ", " $S \rightarrow B$ ", " $S \rightarrow A + C$ ", ...) où chaque règle indique une séquence d'activité possible.
- Lorsqu'une séquence d'actions observées atteint un symbole terminal de l'une des règles alors l'activité de cette règle est reconnue. Le symbole de l'activité est ainsi ajouté à la séquence du niveau supérieur, ainsi de suite jusqu'à ce qu'une séquence d'activités atteint un symbole terminal du comportement S (qui est alors reconnu).
- Un ensemble de comportements (S^1, S^2, S^3, \dots) peut être ainsi décomposé par des règles de production communes (ce qui réduit la taille de la mémoire utilisée) et chaque comportement peut être hiérarchisé sur plusieurs niveaux d'actions et d'activités.
- ✓ Le procédé des grammaires utilisant des règles de productions communes pour différents comportements nous permet de modéliser les **contraintes temporelles** des comportements **se chevauchant**. Le HMM ne dispose pas par défaut de cette habilité à réduire le nombre de fausses reconnaissances lorsque les comportements ne sont pas assez distincts. Pour rappel dans un HMM, pour deux modèles de comportements ayant appris des séquences d'états communes, le modèle sélectionné comme étant le comportement observé est celui donnant la probabilité maximum donc il sera toujours celui qui a le plus de fois rencontré la séquence d'états commune observée.

Une grammaire devient stochastique par l'apprentissage du nombre de fois où une **règle de production (stochastique)** est rencontrée. En se basant sur ces fréquences, une probabilité peut être calculée sur le fait que la séquence d'actions observées correspond à un comportement. Le comportement sélectionné dans une grammaire stochastique est celui ayant la plus haute probabilité selon la séquence d'actions observées.

- Afin de modéliser les contraintes temporelles des comportements se chevauchant, une approche de grammaires d'activités nommée *Stochastic Context Free Grammar (SCFG)* [Pynadath and Wellman, 1998] a été développée. Elle trie les séquences d'observations en donnant un symbole à chaque action primitive et obtient des règles de production par apprentissage. L'algorithme *Minimum Descrip-*

tion Length (MDL) est utilisé pour l'apprentissage de chaque modèle de grammaire d'activité afin de les représenter en un *Hierarchical Bayesian Grammar Network* [Kitani et al., 2005, Kitani et al., 2006]. L'algorithme *Deleted Interpolation* (DI) permet alors de reconnaître temporellement les activités chevauchées. Pour optimiser l'apprentissage et la reconnaissance, les algorithmes MDL et DI considèrent certains symboles comme du bruit pour considérer les séquences de symboles très proches comme étant des mutations de celle la plus représentative.

✗ L'extension du SCFG appelée le *Probabilistic State Dependent Grammars* (PSDG) [Pynadath and Wellman, 2000] modélise les comportements hiérarchisés en utilisant des grammaires de plans (donc étant à un niveau d'observation supérieur que les activités). Néanmoins, [Bui et al., 2002] a prouvé que **l'inférence était erronée** et le modèle PSDG n'a plus été utilisé.

- [Ivanov and Bobick, 2000] propose une stratégie mixte : des HMM pour détecter de simples comportements et ces résultats sont réutilisés (comme symboles dans les règles de production) dans un SCFG afin de détecter les comportements se chevauchant.

→ Le procédé de la **stratégie mixte** est parfaitement dans l'esprit de la fusion de donnée : chaque niveau d'observation utilise l'approche la plus performante et le niveau suivant réutilise les résultats des niveaux précédents. Nous nous utiliserons ce principe sur les différents niveaux d'observation micro, méso et macro.

- Une **politique hiérarchisée** peut être représentée comme une grammaire stochastique. Cette idée adaptée forme l'*Abstract Hidden Markov Model* (AHMM, Figure 3.4(m) page 61) [Bui et al., 2002] qui représente à la fois les hauts et bas niveaux de comportements dans un modèle complet sur des états dépendants. Le plan probabiliste d'un agent y est alors modélisé par une AMP (*Abstract Markov Policy*), qui est une extension d'une politique d'un MDP (*Markov Decision Process*). Où l'AMP est un contingent de plans, dans lequel chaque sous-plan s'applique à un état possible du monde tant qu'il permet d'atteindre l'objectif.

- ✓ Le bruit de l'observation est toujours modélisé par un état caché comme dans un HMM. Pour corriger l'inférence erronée, [Bui et al., 2002] utilise une variante du *Rao-Blackwellised Particle Filter* (RBDF) comme méthode d'inférence hybride pour la reconnaissance de politique. Elle permet d'améliorer la précision et la rapidité d'exécution par rapport à la méthode normale, en combinant l'inférence approximative basée sur l'échantillonnage (sur les variables constantes) avec l'inférence exacte (sur les variables conditionnées par les premières).

✗ En comparant la Figure 3.4(m) avec les précédentes, il nous est facile de comprendre que les modèles hiérarchisés de comportement requièrent des algorithmes approximatifs de reconnaissance à cause de la complexité des calculs liés à l'inférence de ce **réseau Bayésien dynamique**.

→ Par définition, une **approche approximative** va réduire la qualité des résultats pour permettre son application en (quasi) temps réel. Cette nouvelle difficulté oblige les chercheurs utilisant les modèles hiérarchisés à optimiser ces algorithmes approximatifs. Dans le cas contraire, il y a un risque que des comportements soient mieux détectés avec l'un des modèles basiques que nous avons vu précédemment.

II. Hiérarchie à base de décisions stochastiques hiérarchisées

D'un autre point de vue, une **politique hiérarchisée** peut être l'ensemble récursif des politiques jointes de haut niveau (d'une équipe d'agents) jusqu'aux actions primitives (de chaque agent individuel).

• Ce type de modélisation apparaît dans un *Hierarchical Multiagent Markov Process* (HMMP, Figure 3.5(q) page 62) [Saria and Mahadevan, 2004], où les agents coordonnent leurs actions à un haut niveau par un contrôleur central, mais à un bas niveau sans coordination. Ces politiques hiérarchisées invoquent des politiques plus raffinées :

1. À chaque état s , une haute politique π^k (au niveau k) est exécutée par la sélection d'une politique π^{k-1} (du niveau inférieur), selon la distribution $\sigma_{\pi^k}(s)$ et ainsi de suite jusqu'à ce qu'une action primitive soit sélectionnée pour chaque agent.
2. Une fois que π^{k-1} termine dans l'état d , π^k termine alors avec une distribution $\beta_{\pi^k}(d)$ si d est dans l'ensemble des états terminaux de π^k , ou alors il continue par la sélection d'une autre politique du niveau $k - 1$ selon l'état d .
3. Il est à noter qu'il existe un niveau \hat{K} étant le plus bas niveau de coordination (i.e. si $k \geq \hat{K}$ alors ce sont des politiques jointes, sinon elles sont individuelles pour chaque agent).

✗ Ce modèle comporte une explosion du nombre de politiques d'équipe par rapport au nombre d'agents et de groupes (se décomposant en sous-groupes).

• L'extension du HMM utilisant les HMMP est nommée le *Hierarchical Hidden Markov Model* (HHMM, Figure 3.5(r)) [Bui et al., 2004] et permet de modéliser des comportements hiérarchisés sur plusieurs niveaux d'observations allant des primitifs (i.e. des actions simples) aux abstraits (i.e. des séquences d'actions complexes).

• En ajoutant une distribution de **durée** dans chaque état du HMM, le *Hidden Semi-Markov Model* (HSMM) permet de connaître la probabilité que l'état reste inchangé selon une durée explicite avant sa transition vers un nouvel état. Le *Switching Hidden Semi-Markov Model* (S-HSMM, Figure 3.5(s)) [Duong et al., 2005] se base sur le HHMM et sur le HSMM, dont les paramètres sont déterminés par la couche supérieure qui représente les activités de haut niveau où chacune se repose sur une séquence d'activités atomiques (incluant les distributions de durée).

✗ La notion de *Semi-Markovien* est produite par le fait que le modèle ne respecte pas l'**hypothèse de Markov** puisque les états ont des distributions de durées de transitions.

✓ Cette distribution requiert un coût supplémentaire en données d'observations et en temps d'exécution lors de l'apprentissage et la classification. [Duong et al., 2005] propose alors une distribution coaxiale pour modéliser la durée de manière plus réelle que les méthodes d'approximations courantes, puisqu'elle remplace (dans un domaine discrétisé) les composants de phases exponentielles par des distributions géométriques.

III. Hiérarchie adaptée au groupe d'agents

Le HHMM nous permet de modéliser des comportements collaboratifs tels que celui d'équipes d'agents, mais il est sans doute applicable aux comportements collectifs des groupes d'agents.

• Le HHMM a été appliqué au problème de la reconnaissance de comportements de k **personnes** [Nguyen et al., 2005], où à chaque intervalle de temps, une personne génère au plus une observation et peut être bruitée. Le résultat recherché est une hiérarchie d'états cachés dans lequel les états du plus bas niveau sont les "*production states*" et les états du plus haut niveau sont les "*abstract states*". À chaque niveau, un état "*end*" est introduit pour signaler quand le contrôle d'activation retourne à l'état du niveau supérieur. De même que seuls ses états de production doivent émettre des observations.

✓ Puisque l'attribution des personnes aux observations n'est pas fiable, il y a un problème d'association de données qui peut être résolue par une méthode telle que *Joint Probabilistic Data Association Filter* (JPDAF, Figure 3.5(t) page 62) [Nguyen et al., 2005]. Il filtre les données par un algorithme tel que *Rao-Blackwellised Particle Filter* (RBPF). Ce HHMM-JPDAF [Nguyen et al., 2005] inclut alors un ensemble de HHMMs ayant leurs données associées pour traquer et reconnaître les comportements de multiples personnes.

✗ Le point noir reste toujours l'immense complexité de ce modèle. Une solution a alors été développée pour la définition automatique des états.

- Pour produire la structure d'un tel HHMM [Nguyen and Venkatesh, 2005], un algorithme en deux phases peut être utilisé : la première pour découvrir les structures des comportements par un algorithme tel que *Junction Tree* ou *Asymmetric Inside-Outside* et la seconde pour estimer les probabilités des liens entre ces structures (telle que l'apprentissage d'un modèle de mouvement et d'un modèle d'observation pour chaque comportement puis de leurs paramètres par l'algorithme *Expectation-Maximisation*).

→ Contrairement à ce HHMM-JPDAF, la grande partie des recherches présentant des modèles basés sur le HMM ne met pas à disposition un algorithme pour créer la **meilleure structure des états**. Nous avons discuté de ce problème préalablement dans "[Informations utiles pour la définition des états](#)" page 57, puisque la qualité de la structure d'un état est directement reliée au nombre de comportements distincts pouvant être modélisé. Cet avantage permet de réduire notre besoin en supervision et en retour afin de chercher à améliorer la reconnaissance.

IV. Hiérarchie factorisée pour réduire l'explosion du nombre d'états

Face à l'explosion de l'espace des états par la complexité des extensions successives du HMM, la première approche a été de produire des algorithmes approximatifs toujours plus optimisés. La solution suivante a consisté à réduire le nombre des états par **factorisation**. La factorisation n'est pas à confondre avec la discrétisation ou la fusion qui modifient les données définitivement.

Lorsque les données acquises sont issues de multiples capteurs multimodaux, l'AHMM rencontre une explosion de son espace des états. Pour améliorer sa performance de reconnaissance, une méthode a été développée dans le *Factored State-Abstract Hidden Markov Model* (FS-AHMM, Figure 3.4(n) page 61) [Tran et al., 2005].

- Généralement seules quelques variables sont affectées par l'action. Pourtant, les transitions d'états peuvent être compactées en représentant chaque variable d'état par un nœud (sous-état) plutôt qu'en les combinant dans un grand nœud. L'état est factorisé en variables d'états. Le concept de représentation factorisée exploite le fait qu'il y a des indépendances chez les variables d'états dans certains contextes, ainsi les liens probabilistes redondants peuvent être supprimés et leurs nœuds reliés sont factorisés. Ces paramètres s'estiment en utilisant l'algorithme *Expectation-Maximization* (EM).

✓ C'est la première approche qui **réduit la complexité** sans qu'elle ne soit approximative. En effet, le nombre d'états est réduit, mais les informations qui étaient contenues dans les états supprimés sont toujours contenues dans les états factorisés. Un retour aux nombres d'états d'originaux est possible par la défactorisation.

→ Nous avons vu précédemment dans "[Centroïde, une modélisation de groupe](#)" page 47 qu'un état de groupe pouvait être créée en discrétisant sur les états des membres. Nous savons maintenant que nous pouvons factoriser l'espace des états au niveau **méso** afin de modéliser des comportements collectifs avec une complexité moindre et ceci sans perte d'information.

V. Hiérarchie adaptée pour les séquences d'activités à long terme

Un comportement collectif peut se produire sur un court, moyen et long terme. Les précédentes extensions du HMM ont présenté des politiques hiérarchisées pour la détection d'activités jointes (sur le moyen terme) incluant en parallèle des séquences d'actions individuelles (sur le court terme). Il y a donc une évolution possible pour la détection des comportements sur le long terme.

Pour cette évolution, si nous prenons chaque schéma des approches présentées des pages 59 à 62, le procédé de base est l'ajout d'un nœud mémoriel qui, selon le niveau d'abstraction, garde les plans, activités ou actions primitives déjà effectués.

- Pour ce faire, la fusion du AHMM et HHMM a donné lieu à l'*Abstract Hidden Markov mEmory Model* (AHMEM, Figure 3.4(o) page 61) [Bui, 2002, Nguyen, 2003]. Pour cela, il a été ajouté un nœud de mémoire à chaque niveau du réseau. Celui-ci garde en mémoire les séquences d'actions déjà effectuées au niveau courant, selon l'activité choisie par la politique courante du niveau supérieur. Un comportement peut ainsi être défini en une séquence de plus simples comportements ordonnés et y être représenté par une politique abstraite.

- Un comportement simple et un comportement complexe [Nguyen, 2003] peuvent être définis tous les deux en une séquence de comportements. Toutefois lors d'un comportement simple, le choix du prochain comportement au niveau inférieur dépend seulement de la variable d'état courante, tandis qu'avec un comportement complexe, le choix dépend des comportements exécutés dans le passé.

- ✓ L'AHMEM permet de représenter et reconnaître tout comportement complexe sous incertitude puisqu'il est la fusion de toutes les précédentes extensions.

- ✗ L'inférence exacte ne peut suivre l'explosion de l'espace des états de l'AHMEM.

- Sachant une séquence d'observations bruitées obtenue d'un ensemble de caméras, l'inférence approximative s'utilise [Nguyen et al., 2004] pour calculer la probabilité de différents comportements possibles, en temps réel, modélisés par chaque AHMEM. Ces comportements sont ainsi modélisés en une hiérarchie stochastique.

- Le problème est alors porté sur l'apprentissage des paramètres nécessaires pour estimer le lien entre les modèles d'observations et les modèles de mouvements des personnes surveillées. Pour cette tâche, les possibles observations émises d'un état sont compressées en un modèle d'observation. Il en est de même que pour un modèle de mouvement afin d'utiliser des états plus larges, donc qui sont moins soumis au bruit.

→ L'ajout d'une mémoire permet de détecter des comportements sur le long terme, dont nous pourrions en révéler les intentions collectives. La complexité du modèle est toutefois encore plus accrue.

VI. Hiérarchie adaptée au système multi-agent

La dernière extension, malgré sa complexité, permet de modéliser n'importe quelle **activité collective** au niveau **méso**. Elle n'est pas applicable aux **comportements de foules** du niveau **macro**. Toutefois, pour la reconnaissance de l'activité d'un **système multi-agents hiérarchique**, l'intégration des **ontologies** permet de modéliser les possibles interactions avec les entités de l'environnement.

Une récente solution appelée *Multiagent Abstract Hidden Markov with mEmory Model* (M-AHMEM, Figure 3.4(p) page 61) [Gaitanis et al.,] utilise des ontologies qui décrivent les interactions possibles entre deux entités afin d'obtenir une approche contextuelle non déterministe.

- Dans un M-AHMEM, chaque entité est représentée par un AHMEM pour un agent simple ou un groupe d'entités. Pour connecter l'AHMEM du groupe avec l'ensemble d'AHMEM des entités appartenant au groupe, le M-AHMEM utilise un nœud de coordination. L'AHMEM, représentant le comportement d'un groupe d'entités, exprime alors l'activité collective. Ce nœud de coordination peut impliquer différents critères lors de la reconnaissance, i.e. les membres du groupe n'effectueront pas une activité collective de la même manière selon la proportionnalité d'égoïsme et d'altruisme des membres.

✗ Si nous considérons qu'il n'y a que les deux critères extrêmes possibles, cela double les calculs requis pour l'apprentissage et la tentative de reconnaissance, donc pour chaque nouveau critère, l'ensemble des calculs passe à $n + 1$ (où n est le nombre de critères pour la reconnaissance d'un seul groupe d'agents). Le nombre de critères multiplie les calculs de l'apprentissage donc les besoins en données d'observations pour leur apprentissage.

- Une solution apportée dans [Gaitanis and Macq, 2008] pour réduire la complexité est d'utiliser un algorithme tel que le *Rao-Blackwellized Particle Filter* (RBPF) qui prélève les variables clés et produit une inférence exacte par l'algorithme *Junction Tree* sur les variables restantes.

✗ Ce modèle étant récent, son auteur ne l'a appliqué qu'à la reconnaissance des gestes du corps (où chaque partie du corps est un agent faisant partie du groupe du "centre de gravité" du corps). Nous ignorons si ce modèle peut produire de bons résultats avec les comportements collectifs, mais il possède déjà une forte complexité (i.e. Figure 3.4(p)).

→ À notre sens, le M-AHMEM pourrait être appliqué aux comportements collectifs en lui ajoutant une notion de multi-plans/objectifs. Un collectif peut effectuer une activité qui tend vers plusieurs comportements. Prenons un exemple, une foule se déplace dans un environnement comportant des dangers et des abris : les individus paniqués vont fuir (les dangers vers les abris) et/ou se déplacer en groupe (par des règles de *flocking*) ; Tandis que les forces de sécurité vont protéger les paniqués et/ou chercher les responsables et/ou stopper les dangers ; Les responsables vont chercher à faire plus de dégâts et/ou de s'enfuir. Pour chaque individu, nous avons plusieurs types de comportements abstraits produits par leurs objectifs multiples. Il serait plus simple de décomposer de tels AHMEM abstrait en un AHMEM par plan en parallèle, qui se combinerait par un critère indiquant les différents plans suivis. Une sorte de multicouche pour chaque niveau d'activité que l'on tenterait de reconnaître.

VII. Conclusion pour la hiérarchisation des comportements abstraits

La complexité de l'espace des paramètres, malgré la décomposition, rend ces modèles impossibles à reconnaître en temps réel sans l'utilisation de méthodes approximatives (notamment pour l'inférence). Afin d'obtenir une bonne qualité de reconnaissance, la quantité de données d'observations requises pour apprendre chaque comportement augmente avec la complexité de l'espace des paramètres, ce qui augmente le temps d'apprentissage. Une solution pour obtenir cette quantité de données est de les répliquer en y ajoutant une part d'aléatoire faible, notamment par les méthodes d'échantillonnages (qui est une méthode approximative).

Chaque modèle récent cherche à améliorer la qualité des résultats du modèle précédent sans pallier à la limite commune : la complexité est telle qu'elle oblige d'utiliser une méthode de reconnaissance et d'apprentissage approximative. À quoi cela sert-il d'améliorer les modèles s'ils sont inapplicables dans la réalité ?

Conclusion

En suivant l'évolution des modèles d'apprentissage et de reconnaissance, nous pouvons observer une complexité grandissante par l'ajout d'informations (notamment au HMM). L'objectif est de modéliser des comportements collectifs sur tous les niveaux d'observation : les actions primitives, les activités jointes (coopératives et collectives), les plans, les politiques,... afin de déterminer les intentions des agents observés.

Nous ne pouvons pas adapter ces méthodes aux comportements collectifs sans devoir passer par encore plus de complexité (car plus d'états, donc plus d'approximations), plus de données d'observations pour plus d'apprentissages semi-supervisés (puisque c'est nous qui y déterminons les différents niveaux du modèle hiérarchique d'activités).

Dans l'apprentissage et la reconnaissance des comportements, les approches révèlent que plus nous cherchons à améliorer la diversité des comportements détectables, plus la complexité des modèles augmente que ce soit pour :

- ▷ **la décomposition** : concerne la manière de séquencer, factoriser et hiérarchiser les comportements des niveaux d'observation micro, méso et macro ;
- ▷ **l'apprentissage** : concerne le besoin en quantité et en qualité des données d'observations pour chaque comportement ;
- ▷ **la reconnaissance** : concerne l'obligation d'utiliser des algorithmes approximatifs que nous cherchons toujours à optimiser afin de réduire la perte de qualité des résultats.

La complexité des modèles pour en améliorer les résultats est telle qu'ils deviennent inapplicables sans perte de qualité des résultats par des méthodes approximatives de reconnaissance toujours plus optimisées. Nous préférons remettre à plat la méthode de décomposition et de hiérarchisation par trois niveaux de détection : micro, méso et macro de sorte que notre modèle soit applicable quelque soit la situation, les entités surveillées et l'environnement, asymétrique dans notre cas.

La grande majorité des modèles de l'état de l'art pour la détection des comportements collectifs n'essaye pas de comprendre le *pourquoi*, mais uniquement le *comment*. Dans notre cas d'étude, nous avons ajouté ce *pourquoi* afin de déterminer la raison (ou l'objectif) qui a provoqué ces comportements.

Deuxième partie

Modèles de Comportements Collectifs : Détection Micro, Méso et Macro

"La foule est la bête élémentaire, dont l'instinct est partout, la pensée nulle part."

André Suarès

Introduction

Lors d'une situation d'urgence et d'évacuation, il est souvent **impossible** d'interpréter manuellement le comportement complexe d'une foule. C'est essentiellement dû au manque de personnel et de temps nécessaires pour comprendre la situation. Dans la littérature, un système de surveillance utilisant des méthodes de fusion de données rend possible une évaluation automatique de la situation (*situation awareness*). En utilisant le domaine d'intelligence distribuée (*swarm intelligence*), nous proposons une approche basée sur un système multi-agents pour simuler et détecter des comportements collectifs primitifs émergeant d'une foule en panique. Pour des scénarios spécifiques, cette approche permet l'**anticipation** de comportements collectifs en temps réel aussi bien que l'**identification** de comportements anormaux. Ici la notion de détection signifie la possibilité d'apprendre, d'identifier et d'anticiper différents comportements par un modèle probabiliste. Notre approche de détection de comportement collectif d'une foule en panique en temps réel utilise les algorithmes d'apprentissage et de reconnaissance du **modèle de Markov caché** (HMM).

L'absence du *pourquoi* dans les approches de détection nous a amenés à créer un modèle qui l'intègre directement dans la définition des états, que nous nommons **états relatifs**. En se basant sur ceux-ci, il nous est ainsi possible de détecter des groupes et leurs comportements (objectivés) envers tous les objectifs. Ces objectifs sont toutes entités (spatialisées et temporisées) de la situation dont nous pouvons observer un comportement relatif. Certaines règles sur ces résultats nous permettent de connaître s'ils ont une cible, s'ils sont en train de fuir ou de contourner,... ou de menacer. En d'autres termes, nous pouvons le voir comme une détection de leurs **intentions envers un objectif**.

En réaction aux limites de l'état de l'art, nous avons développé un **modèle de système multi-agents permettant la détection à plusieurs niveaux d'observations**. Le chapitre 4 page 79 présente deux niveaux de notre modèle : (section 4.1 page 80) Des agents **micro** simulent une foule d'individus (en panique) dans un environnement asymétrique ; (section 4.2 page 82) Ils sont surveillés par des agents **macro** qui identifient les événements collectifs (paniques, violences) de manière à les apprendre et à les anticiper en temps réel ; (chapitre 5 page 89) Ces derniers alerteront des agents **méso** pour (1) l'identification des groupes, (2) la reconnaissance des comportements (objectivés) des groupes (e.g. menaçant), (3) voire de leurs intentions (objectivées) envers des objectifs.

Chapitre 4

Détection Macro d'une Simulation Micro : Application à la foule en panique

Sommaire

4.1	Micro - Modélisation des agents	80
4.1.1	Agent - Algorithme de décision de sa direction	80
4.1.2	Architecture BDI - Croyances, Désirs, Intentions	81
4.2	Détection des activités collectives de panique	82
4.2.1	Macro - Apprentissage des mouvements de foules	83
	A. Apprentissage des chemins empruntés par les agents	83
	B. Apprentissage des interactions physiques	84
4.2.2	Micro - Anticipation des chemins individuels	86
4.3	Conclusion	87

Notre cas d'étude à propos des scénarios asymétriques étant très vaste, nous avons simulé au niveau micro une foule en panique pour obtenir des données d'observations sur lequel tester nos méthodes d'apprentissage de niveau macro et d'anticipation de niveau micro.

La simulation de **rassemblements sociaux** dans un environnement virtuel nous épargne la difficulté d'obtenir de vraies mesures pour notre cas d'étude. Afin de limiter la complexité, nous avons choisi de simuler et détecter seulement les mouvements collectifs d'une foule en panique en raison de ses **effets dévastateurs**. Cette simplification nous a permis de valider l'efficacité de nos techniques. En premier lieu, nous simulons des mouvements d'une foule en panique en utilisant différentes techniques d'intelligence distribuée de la littérature scientifique actuelle. Dans un second temps, nous présentons une méthode innovante pour détecter les mouvements récurrents de panique dans un environnement spécifique. L'**objectif** est d'obtenir une évaluation automatique de la situation pour **signaler** des problèmes récurrents liés à l'environnement et **anticiper** les comportements complexes en temps réel pendant une panique collective. Ce genre d'outil pourrait être inclus dans un smartphone ou n'importe quel système de surveillance afin d'aider les forces de sécurité (et les personnes présentes) à agir dans les meilleures conditions.

En se basant sur notre état de l'art de la section "[Micro vs Méso vs Macro : Trois niveaux de modélisations](#)" (page 23), chacun des niveaux de modélisation révèle des avantages et des limites. Notre choix

s'est porté sur le niveau micro, puisqu'il permet une émergence récurrente de comportements collectifs qui sont compréhensibles selon la situation asymétrique. Nous présentons notre 1^{er} objectif (section 4.1) qui est la capacité de simuler des mouvements collectifs de panique les plus réalistes possible. Ceci nous permet notre 2^{ème} objectif qui est de tester notre modèle de détection sur les données d'observations produites (section 4.2 page 82).

4.1 Micro - Modélisation des agents

Notre modèle d'agent en panique est basé sur les équations et les comportements de l'état de l'art dans la section "[Stimuli communs d'une foule](#)" (page 26).

Afin de se rapprocher le plus possible de la réalité, les agents ne communiquent pas entre eux. En conséquence, cette restriction limite leurs connaissances : ils possèdent seulement leur propre observation partielle de leur environnement immédiat, tels que les mouvements des autres agents, la présence d'obstacles, des zones de dangers (menaces) et de sécurité (abris). Les agents se doivent donc de décider de leur prochaine action en temps réel en fonction de leur information incertaine et incomplète de la situation. À cela s'ajoute le nombre minimum d'agents requis pour que nous distinguions une foule (et non pas deux trois groupes), les agents ont donc besoin d'un algorithme de décision à basse complexité.

4.1.1 Agent - Algorithme de décision de sa direction

Nous parlons d'un algorithme de décision et non de planification. La planification laisse suggérer que le chemin que pourrait emprunter chaque agent pourrait être prédéterminé sur le long terme. Cependant, nous sommes dans un contexte où l'agent est paniqué, réagissant instinctivement à chaque nouvelle observation de son environnement par une action non préalablement planifiée.

Chaque agent choisit l'action selon ses mouvements possibles, ses désirs et ses intentions (i.e. le modèle B.D.I). Tant qu'ils sont proches d'une zone dangereuse et en dehors d'une zone de sécurité, les agents cherchent à :

- s'enfuir en priorité avec une vitesse excessive, quitte à produire des bousculades : selon les calculs d'interactions physiques du modèle d'Helbing présenté dans la section "[Stimuli communs d'une foule](#)";
- suivre les autres individus en mouvement de groupe : selon le modèle décrit dans "[Notion de flocking](#)" page 28 et le modèle SCT décrit page 27 ;
- éviter de tourner en rond et explorer si besoin : selon le modèle défini page 29 qui déposent virtuellement des phéromones afin d'avoir une mémoire simple des zones déjà explorées ;
- faire attention à ne pas être stoppé : un agent cherchera à éviter de se retrouver coincé (voire étouffé) en passant par un endroit exigu (i.e. en manque d'espace vital) alors qu'il perçoit un autre chemin plus sûr.

Notre **algorithme 1** est ce qui nous fait défaut afin que les agents décident individuellement de la direction qu'ils prennent. Cette décision s'effectue à chaque instant en se basant sur sa propre observation de la situation et de ses intentions.

Notre agent a besoin d'une architecture qui lui permet d'avoir un comportement humain.

Algorithme 1 : Un agent décide de sa direction.

Data : $D \leftarrow \{ \dots \}$ // toutes les directions qui sont libres pour l'agent (incluant celle qui correspond à rester sur place). Les possibilités sont réduites par son environnement proche (les obstacles, les dangers et les autres agents).

$P \leftarrow \{ \dots \}$ // toutes ses perceptions (incluant toutes les positions occupées par les autres agents, les obstacles, les zones de dangers, les zones de sécurité et les phéromones).

```

1 begin
2    $valueBest \leftarrow -\infty$  // la plus haute valeur donnée par une direction;
3    $directionBest \leftarrow$  la direction actuelle de l'agent;
4   forall  $d \in D$  do
5      $value \leftarrow 0$ ;
6     forall  $p \in P$  do
7       if la distance entre l'agent et  $p$  diminuera s'il se dirige selon  $d$  then
8          $value \leftarrow value + ((\text{la récompense associée à } p) / \text{distance})$ ;
9       else
10         $value \leftarrow value - ((\text{la récompense associée à } p) / \text{distance})$ ;
11      if  $value > valueBest$  then
12         $valueBest \leftarrow value$ ;
13         $directionBest \leftarrow d$ ;
14 end
15 return  $directionBest$  // La meilleure direction pour l'agent.
```

4.1.2 Architecture BDI - Croyances, Désirs, Intentions

L'architecture BDI (sous-section 1.2.1 page 24) nous permet d'avoir un agent en panique qui aura un comportement hybride assez réaliste :

- ▷ **Réactif** : notre algorithme 1 lui permet de décider de ses actions par réflexe comme en réponse aux stimuli observables de son environnement ;
- ▷ **Cognitive** : une planification à long terme pour atteindre ses intentions qui se basent sur ses désirs (répercutés immédiatement sur ses actions) et sur ses croyances (fusionnant ses observations de l'environnement).

Une illustration de ce que suit l'architecture BDI de chaque agent paniqué sera plus simple à comprendre par la visualisation.

L'**architecture cognitive des agents** que nous avons produits se définit ainsi :

- ✘ ses perceptions : les autres agents, les obstacles, les dangers, les abris, tant qu'ils sont dans son champ visuel ;
- ✘ ses règles de décision (décrits par l'algorithme 1) : une architecture BDI où le choix du prochain déplacement de l'agent résulte de celui ayant la meilleure **récompense augmentée**. La Figure 4.1 présente chaque agent par une flèche bleue dans la direction de son mouvement ou un rond bleu par l'absence de déplacement. La *récompense augmentée* est la somme des récompenses par le fait :
 - * de s'éloigner des zones dangereuses rouges (récompense positive, Figure 4.1(a) où les agents magenta sont morts) ;

- * de se rapprocher des zones sécurisées grises (récompense positive, Figure 4.1(b)) ;
 - * de se déplacer en groupe suivant les règles de *flocking* (récompense positive, Figure 4.1(c)) ;
 - * d'éviter de tourner en rond (récompense négative en présence de phéromones, Figure 4.1(d)) ;
 - * et de faire attention à ne pas être stoppé par des obstacles noirs (Figure 4.1(c)) et par la densité d'un trop grand nombre d'agents proches (récompense positive).
- ✕ **son ensemble d'actions** : se déplacer avec une vitesse et une direction calculée en fonction du modèle d'Helbing ("Stimuli communs d'une foule" page 27) selon la direction désirée de l'agent (décidée par l'algorithme 1).




FIGURE 4.1 – Les comportements des agents pour chacune de leur récompense.

Initialement, les agents connaissent leurs positions. De plus, ils ont connaissance des obstacles, mais pas des dangers. Quand les dangers apparaissent, la perception partielle de chaque agent est obtenue en temps réel par la vision des positions des entités de l'environnement (obstacles, agents, dangers, abris) avec une mise à jour constante par son propre déplacement (qui modifie son champ de vision).

Les illustrations 4.1 montrent quelques comportements d'une foule en panique avec des résultats proches de ceux présentés par la littérature du chapitre "Comportements Collectifs" (page 13). Nous considérons que la simulation est suffisamment efficace pour l'utiliser lors des tests de notre modèle de détection. Nous reviendrons dans la partie III et notamment au chapitre 6 page 109 à propos des résultats d'expérimentation de ce modèle.

Dans un futur proche, nous pourrions adapter ce système en utilisant un *serious game* afin d'améliorer le modèle de simulation par une observation en trois dimensions.

4.2 Détection des activités collectives de panique

Avec la maîtrise de cet environnement virtuel qui nous produit des observations d'une foule en panique, nous allons présenter un modèle d'**apprentissage** des comportements collectifs primitifs (telle que la panique) au niveau **macro** pour leur **anticipation** au niveau **micro**. Pour ceci, nous utilisons un unique HMM (section 3.2 page 55) de niveau **macro**.

Pour la détection d'un comportement de panique collective, nous nous sommes intéressés en premier lieu aux caractéristiques suivantes :

- ◇ Les chemins récurrents empruntés par les agents,

◇ Les positions récurrentes des chocs physiques entre les agents.

En utilisant un simulateur de foule en panique, le premier objectif de notre détection est d'apprendre les mouvements collectifs récurrents de la foule en panique dans un environnement spécifié. Le second objectif est d'améliorer la sécurité de la foule en utilisant notre modèle. Pour cela, nous devons anticiper les problèmes récurrents en les détectant durant les simulations :

1. Révéler les positions récurrentes où se produisent les interactions physiques lors des mouvements collectifs,
2. Anticiper en temps réel les chemins qui vont être empruntés par les agents surveillés,
3. Alerter des anomalies de comportements quand les agents effectuent un comportement que le système ne reconnaît pas parmi ceux préalablement appris.

Pour ceci, nous avons choisi d'utiliser un **modèle de Markov cachée** (HMM) (section 3.2 page 55) pour apprendre, reconnaître et anticiper les comportements. La plus grande difficulté avec ce modèle probabiliste est de définir correctement l'ensemble des états pour représenter chaque situation possible du monde dans un état actuel. Après leurs définitions, le processus d'apprentissage sur les séquences d'observations (issues de la simulation) permet d'obtenir les probabilités de transitions. La manière de décomposer l'espace en états garantit donc les avantages et les limites de la reconnaissance d'un modèle de comportement. C'est-à-dire sa capacité à prendre en compte les incertitudes des observations.

Pour décrire notre modèle de détection de comportements, nous pouvons rappeler **deux faits** : (1) Considérons un composant dans un système multi-agents muni de capacités d'interactions [Fallah et al., 1998], un comportement local peut être modélisé sur les interactions exécutées par les agents surveillés ; (2) L'utilisation des interactions locales permet de faire émerger une organisation perçue, ce qui est la représentation d'un comportement collectif [Sabouret and Sansonnet, 2001].

Dans ce modèle, les agents générant les comportements individuels sont tous piétons. Par l'apprentissage des différents chemins possibles pour chaque position éventuelle d'un agent dans la foule, nous pouvons anticiper stochastiquement les comportements des mouvements de foule.

4.2.1 Macro - Apprentissage des mouvements de foules

Au niveau micro, le chemin emprunté par chaque agent est appris dans un unique modèle HMM de niveau macro des déplacements collectifs.

A. Apprentissage des chemins empruntés par les agents

Le fait de simuler les comportements collectifs de paniques dans un même environnement virtuel nous permet de simuler des milliers d'itérations et d'en extraire les comportements collectifs dans un modèle macro.

Chaque itération nous fournit un chemin emprunté par chaque agent. Les déplacements d'un agent est le résultat d'une séquence de décisions calculée en fonction de sa situation (i.e. l'algorithme 1), donc afin d'éviter un surapprentissage des mêmes déplacements, certains paramètres sont à prendre compte :

- * Chaque itération sera unique : les positions initiales des agents sont aléatoires et ce nombre d'agents est incrémenté après suffisamment d'itérations pour avoir eu la plus grande variété possible de mouvements de groupe.
- * Chaque itération se termine quand les agents finissent leur comportement de panique : une fois arrivés en zone sécurisée et/ou lorsqu'ils ne peuvent plus se déplacer.

Les chemins empruntés par chaque agent vont être appris dans un modèle HMM macro.

Compte tenu du nombre très important d'états et de sous-états, du nombre de chemins observés empruntés par les agents (un par agent) et du nombre d'itérations, il y a une **explosion** du nombre de séquences d'observations à apprendre pour cet unique HMM. L'algorithme d'apprentissage *Baum-Welch* couramment utilisé (section 3.2.1 page 55) se retrouve **inapte** à être utilisé. Il a été conçu de manière à extrapoler les meilleures probabilités en se basant sur un grand nombre (mais toutefois limité) de séquences d'observations (qui correspondent stochastiquement aux séquences d'états cachés). Avec notre environnement virtuel (totalement contrôlable), pour l'apprentissage, nos séquences d'observations sont les séquences d'états cachés complètes et certaines (i.e. sans incertitude). Nous allons alors utiliser une manière plus "directe" d'apprendre ces transitions d'états cachés, sans recourir à la couche observation (i.e. Figure 3.1 page 56).

Pour ce faire, des états spécifiques sont utilisés. Nous découpons la carte (en vue 2D) en une grille où chaque case est une position possible pour un agent et correspond à un état q_i ($i = \{x, y\}$ pour la colonne x et la ligne y). En d'autres termes, l'état d'un agent est représenté par sa position observée. L'apprentissage du modèle s'effectue avec les séquences d'observations produites par la simulation de milliers d'itérations dans un environnement stable (i.e. sans perturbation des chemins possibles). Chaque déplacement des agents d'un état q_i vers un état voisin q_j augmente le nombre de transitions t_{ij} gardé en mémoire. En résultat, la probabilité $a_{ij} = t_{ij} / \sum_{k \in K} t_{ik}$ d'aller d'un état q_i vers un état voisin q_j est le nombre de transitions t_{ij} divisé par la somme de toutes les transitions observées pour aller dans chaque état possible du voisinage K de l'état q_i (lui-même y étant inclus).

Cependant, la décision d'un agent (i.e. sa direction pour son prochain état) peut être modifiée quand ses états (positions) voisins sont déjà occupés par des agents ou des obstacles. Durant le processus d'apprentissage, la présence récurrente d'obstacles produit du bruit dans les probabilités de transitions.

Afin de réduire cet effet, un ensemble de sous-états est créé pour chaque état basique q_i . Chaque sous-état q_i^j ($\in q_i, \forall j$) représente une combinaison possible des états voisins déjà occupés (soit 2^k combinaisons possibles, avec k le nombre d'états voisins). La Figure 4.2 présente certains sous-états quand il y a huit états voisins possibles (donc $2^8 = 256$ sous-états possibles) avec quelques-uns déjà occupés. Sur cette illustration, l'agent est au centre (rond bleu) et ne peut que se déplacer dans les cases voisines inoccupées (blanches). L'apprentissage du modèle est alors exécuté sur ce nouvel ensemble de sous-états au lieu de l'ensemble des états basiques.

Les expériences de la partie suivante nous démontreront la précision, les avantages et les limites d'utiliser seulement l'ensemble des états ou la version incluant chaque ensemble de sous-états.

B. Apprentissage des interactions physiques

La possibilité d'apprendre les différentes formes et le nombre d'interactions physiques entre les individus lors de mouvements de panique nous permet d'envisager des solutions.




FIGURE 4.2 – L'ensemble des sous-états $q_{x,y}^j$ pour chaque état q_i possible si chaque état comporte neuf états voisins (s'incluant lui-même)

Nous ajoutons une variable supplémentaire à chaque état basique q_i de l'agent (et non pas aux sous-états) : ψ_i qui est le nombre de fois où une interaction physique s'est produite par un frôlement, un contact physique, une bousculade ou un piétinement (qui entraîne de graves blessures) à la position de l'état q_i .

Pour faire la différence entre les types d'interactions physiques, nous utilisons les paramètres de l'étude produite par le *Bureau de la protection des infrastructures essentielles et de la protection civile du Canada* [Canada and Hanna, 1995] qui indique les besoins pour les mouvements de foule tels que les **densités critiques de la foule** (*critical crowd densities*) [Fruin, 1993]. Elles représentent les conditions de mobilité qui se répercutent directement sur les comportements de la foule, tels que les valeurs suivantes à propos de la surface minimale disponible par individu (étant debout) lorsqu'elle est :

- > $2.32 \text{ m}^2 \approx 25 \text{ ft}^2$: (inclus dans $\psi_i(a)$) les piétons se déplacent en marchant avec une vitesse normale, pouvant éviter et contourner les passants ;
- > $0.93 \text{ m}^2 \approx 10 \text{ ft}^2$: (inclus dans $\psi_i(a)$) les mouvements possibles sont sensiblement restreints et la vitesse des piétons est notablement réduite ;
- > $0.46 \text{ m}^2 \approx 5 \text{ ft}^2$: (inclus dans $\psi_i(a)$) la mobilité de chaque piéton est réduite, ce qui est caractéristique des déplacements en groupe ;
- > $0.28 \text{ m}^2 \approx 3 \text{ ft}^2$: (inclus dans $\psi_i(b)$) des frôlements et des contacts involontaires se produisent ;
- > $0.19 \text{ m}^2 \approx 2 \text{ ft}^2$: (inclus dans $\psi_i(c)$) la foule se bouscule et des tensions psychologiques potentiellement dangereuses commencent à apparaître ;
- > $0.14 \text{ m}^2 \approx 1.5 \text{ ft}^2$: (inclus dans $\psi_i(d)$) c'est la caractéristique commune des événements désastreux parmi la foule, comme les suffocations et les piétinements.

Lors de l'apprentissage de chaque ψ_i , nous gardons les nombres a, b, c, d , tels que $\psi_i(a)$ donne le nombre de fois où un agent est dans cet état sans avoir eu d'interactions physiques (et pour b, c, d se référer ci-dessus).

En mémorisant ces interactions physiques, nous serons capables d'extraire les **zones à haut risque de bousculades**. Des **solutions préalables** pourront être envisagées avant et/ou pendant les rassemblements sociaux afin d'en **réduire les risques** en cas de panique collective. Si cela se produit, la sous-section suivante à propos de l'anticipation des chemins empruntés (par les agents paniqués en temps réel) pourrait être **combinée** aux connaissances préalables des zones à haut risque afin que les forces de sécurité sachent précisément où il y a le plus besoin d'intervenir. Un tel système serait une aide précieuse puisque dans ce genre de situation, les forces de sécurité sont souvent dépassées par les événements (i.e. Photographie

1(a) page 4). Ils n'interviennent qu'aux endroits connus (i.e. les sorties et les lieux observés) qui ne sont pas nécessairement les endroits clés comportant un risque.

4.2.2 Micro - Anticipation des chemins individuels

Le modèle HMM macro des mouvements collectifs est appliqué à anticiper les mouvements individuels au niveau micro, par les probabilités de transitions apprises entre les états.

La Figure 4.3 est le résultat d'un processus d'apprentissage. Elle illustre deux exemples de sous-états quand un agent est dans l'état q_i . $q_{x,y}^1$ qui se produit lorsque le voisinage complet est inoccupé (blanc) et q_i^{17} quand deux états voisins sont déjà occupés (noirs). Les probabilités de transitions entre ces deux états sont différentes puisque l'agent se déplaçant doit contourner ses obstacles par des états intermédiaires, ce qui augmente les autres probabilités de transitions. La position rouge indique la direction la plus probable qu'un agent emprunterait dans cette situation. Ces probabilités sont un exemple de résultats d'apprentissage du modèle HMM macro dont le processus est décrit dans la section précédente 4.2.1 page 83.

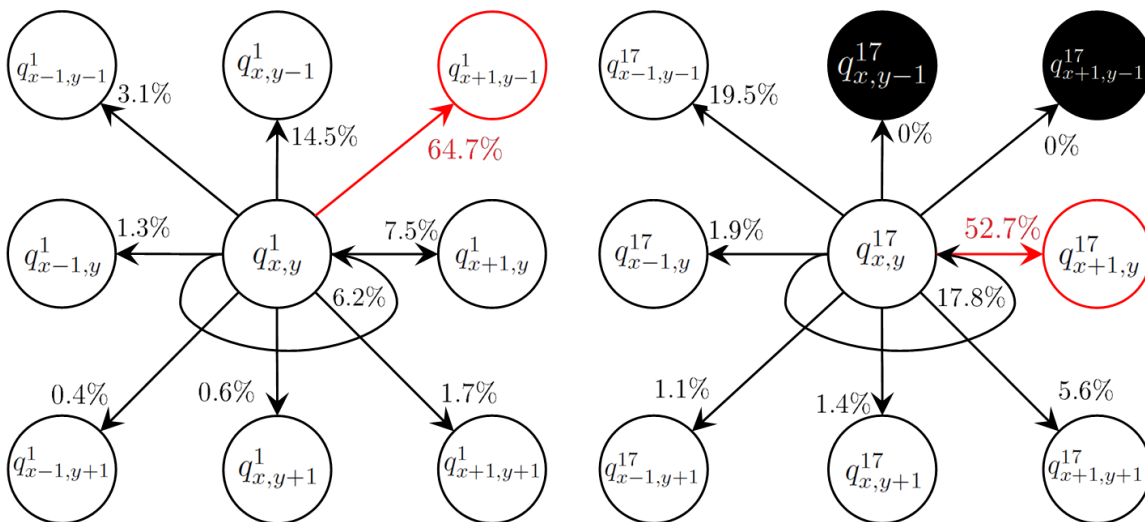


FIGURE 4.3 – Un exemple de probabilités de transitions dans l'état $q_i = \{q_i^1, \dots, q_i^{17}, \dots\}$ après apprentissage

Ces processus discrets satisfont la **propriété de Markov à l'ordre k** qui implique que les probabilités de transitions dépendent seulement des n états précédents. Nous en obtenons ainsi **une chaîne Markovienne de premier ordre** avec des états non directement observables (internes aux agents). En l'utilisant, nous pouvons prédire les futures positions des agents. Par exemple, la séquence d'état $\{q_{0,0}, q_{1,0}, q_{2,1}, q_{3,1}, q_{3,2}, q_{4,2}\}$ de la Figure 4.4 est le chemin le plus probable qu'empruntera un agent commençant dans l'état $q_{0,0}$.

L'explication de notre processus d'anticipation des chemins individuels nous amène déjà à présenter des résultats d'apprentissage. Les expériences de la partie suivante nous démontreront la possibilité d'appliquer en temps réel cette anticipation et les possibilités d'identifier les zones à haut risque de bousculades.




FIGURE 4.4 – Le chemin le plus probable d’un agent parmi un ensemble de positions

4.3 Conclusion

Dans ce chapitre, nous avons présenté deux domaines de recherche que nous avons étudiés pour **la simulation et la détection de comportements collectifs** basée sur une approche multi-agents sur deux niveaux de modélisations **micro** et **macro**.

Les travaux menés dans ce chapitre ont permis de mettre en place deux résultats qui sont : [Patricx et al., 2011] et [Patricx et al., 2012].

Suite à notre état de l’art, nous avons utilisé notre modèle basé sur les **Hidden Markov Models pour apprendre, identifier et anticiper** certaines formes de comportements collectifs. Notre système pourrait être utilisé pour prévenir des risques durant des rassemblements sociaux. L’environnement peut être modifié en fonction des résultats de détection des positions récurrentes où se produisent des interactions physiques afin de les réduire. Un système de surveillance pourrait anticiper les mouvements collectifs en temps réel.

Dans un futur proche, nous pourrions adapter ce système en utilisant un **serious game** et tenter de détecter les intentions des groupes. Ces différentes intentions sont supposées être reflétées par différents comportements collectifs. Nous anticipons un comportement mais pas l’objectif et encore moins l’intention qui l’a déclenché, cette perspective est le propos du chapitre suivant.

"Pose ta main sur un poêle chaud pendant une minute, et cela te semblera une heure. Assois-toi à côté d'une jolie fille pendant une heure, et cela te semblera une minute. C'EST ça la Relativité."

Albert Einstein

Chapitre 5

Méso - Détection des Comportements Collectifs Objectivés

Sommaire

5.1	Décomposition par les états relatifs discrétisés	90
5.1.1	État fusionné d'un groupe	91
5.1.2	État relatif discrétisé d'un groupe envers un objectif	92
5.1.3	Séquencement d'un comportement objectivé par des états relatifs discrétisés	94
5.2	Identification des groupes	94
5.2.1	Micro → Méso - Approche par la proxémie et les séquences d'états relatifs	95
5.2.2	Macro → Méso - Approche par la proxémie et l'utilité de groupe	97
5.3	Assignement des comportements objectivés aux groupes	99
5.4	Estimation des intentions	100
5.4.1	Intentions par l'évaluation des comportements objectivés sur le long terme	101
5.4.2	Intentions par les états objectivés discrétisés	102
5.5	Conclusion	104

Précédemment, dans le chapitre 4 page 79, nous avons décrit une approche [Patricx et al., 2012] qui nous permet d'évaluer les risques durant les rassemblements sociaux (telles que les situations d'urgence et d'évacuation) en fusionnant des approches de niveau micro et macro. Elle présente une approche pour l'apprentissage, l'identification et l'anticipation des problèmes récurrents tels que les mouvements de panique et les zones à haut risque de bousculades. Ce chapitre a fait l'objet d'un dépôt de **brevet européen** [Patricx et al., 2013a] et d'une publication scientifique [Patricx et al., 2013b].

Dans un contexte de gestion de crise, obtenir l'évaluation de la situation (*situation awareness*) est un challenge à cause de la complexité de l'environnement et les ressources limitées des forces de sécurité. Les différentes menaces émergentes sont difficiles à identifier et les comportements de la foule (séparé en groupes) sont difficiles à interpréter et à gérer pour les forces de sécurité. Afin d'aider à résoudre ce problème, nous proposons une méthode pour détecter des **menaces** et comprendre la situation par l'analyse des **groupes**, de leurs **comportements collectifs**, de leurs **objectifs** et de leurs intentions. En d'autres termes, ce qui se produit durant un scénario asymétrique.

Nous nous basons sur un ensemble appris de modèles de **comportements "objectivés"**²⁰ de groupe (*goal-based group behaviors*) et de séquences d'observations de groupes. La méthode proposée calcule l'état estimé du groupe, avant l'utilisation d'*Hidden Markov Model* pour reconnaître **le comportement du groupe par rapport à chaque objectif possible**. Les algorithmes proposés complètent notre processus de détection par l'identification d'individus considérés comme menaçants (afin de déclencher une alerte) et par l'anticipation de l'intention de ses individus.

5.1 Décomposition par les états relatifs discrétisés

Un **état relatif discrétisé**, nommé ainsi par nos soins, est un nouveau type de donnée qui représente notre principale **innovation** et concerne trois faits importants à rappeler :

1. Le niveau **méso** d'observation permet une complexité moindre pour la détection des comportements collectifs ;
2. Les approches de l'état de l'art n'intègrent pas la **raison** pour laquelle un comportement a été exécuté par des agents ;
3. Le **séquencement** d'un comportement complexe est une méthode de décomposition qui réduit la difficulté de sa modélisation.

Il est à savoir que l'approche présentée dans ce chapitre n'est pas uniquement celle publiée dans [Patricx et al., 2013b], puisque l'idée complète sur les **états relatifs** (dont un processus complet utilisant toutes variables observées et des ontologies comme base de connaissances sur ces variables) est seulement incluse dans le brevet [Patricx et al., 2013a] P300151 déposé le 3 mai 2013. Cela n'en affecte en rien la réutilisation de la démarche innovante proposée dans [Patricx et al., 2013b] puisqu'elle ne s'intéresse qu'aux états relatifs discrétisés.

La détection en temps réel d'un comportement multi-agents est un problème hautement complexe. En effet, si l'état du groupe est défini en se basant sur les états de ses membres, alors un modèle de comportement de groupe aura une complexité proportionnelle au nombre de variables $|A| \cdot |S| \cdot T$ où A est l'ensemble des agents et S est le nombre de variables pour chaque état d'agent, du point de départ des observations à $t = 0$ jusqu'au temps actuel $t = T$. En conséquence, la taille (l'espace utilisé) du modèle de comportement devient impossible à gérer sur le temps.

Notre approche consiste à définir un ensemble de séquences d'**états relatifs discrétisés (DR)** qui **modélise un comportement objectif de groupe** (*goal-based group behavior*). Une séquence d'états relatifs discrétisés représente une discrétisation de l'évolution entre deux moments successifs concernant la différence entre l'état centroïde d'un groupe et l'état d'un objectif. Ce centroïde du groupe est calculé à partir de l'état des individus appartenant au groupe. De cette manière, le nombre d'agents / personnes dans le groupe n'a plus d'impact sur la complexité du problème de reconnaissance des comportements collectifs de groupe.

Un fait important à propos des **objectifs** (*goals*) d'un groupe est qu'ils sont toutes entités de l'environnement (en excluant les membres du groupe) telles que d'autres individus / groupes, des positions importantes, des infrastructures critiques, des zones dangereuses et sécurisées,... La méthode proposée fournira une valeur de **probabilité** indiquant l'estimation que ce groupe exécute ce comportement envers

20. i.e. orienté objectif, "*Collective Behavior is Objectified*" d'après [Kristensen and May, 1996].

cet objectif. Par exemple, l'objectif peut être une cible ou une menace, ce qui se reconnaît par un comportement de suivi ou de fuite. La séquence d'actions d'un groupe a été décidée en prenant en compte l'existence de ces objectifs (entités). Ainsi, nous les appelons les **comportements objectifs de groupe**.

5.1.1 État fusionné d'un groupe

La représentation d'un groupe peut être notre **état fusionné** de niveau méso. Il possède quelques différences par rapport à ceux présentés dans notre état de l'art (notamment dans "[Centroïde, une modélisation de groupe](#)" page 47).

Les points suivants sont un rappel de notre état de l'art pour mieux positionner notre modèle :

▷ Les observations du comportement d'un agent sont obtenues de manière continue et doivent donc être segmentées à intervalles réguliers afin d'obtenir des séquences d'états observables. Avoir une plus grande quantité de séquences sera utile pour l'apprentissage du comportement, mais il faudra déterminer quelle longueur de la séquence donne le meilleur résultat d'apprentissage et de reconnaissance. Ce séquençement continu oblige aussi à tenter de reconnaître chaque comportement sur chaque séquence produite, ce qui augmente le nombre de calculs en temps réel.

▷ Pour la modélisation de chaque comportement, nous utilisons un HMM qui permet de représenter un comportement sur un ensemble d'états cachés ayant une distribution de probabilité de transition sur ces états. Toutes séquences d'états observables de ce comportement nous permettent d'obtenir ces probabilités de transitions par un algorithme d'apprentissage. Un algorithme de reconnaissance répond par une probabilité quand il est questionné sur le fait qu'une séquence d'observations d'un comportement (actuellement surveillé) correspond au modèle appris de ce comportement.

▷ Différents niveaux d'observations nous permettent de modéliser une représentation stochastique d'un comportement de groupe :

- (1) Le niveau micro concerne les rôles des agents qui impactent leurs possibles activités individuelles ;
- (2) Le niveau méso concerne les activités exécutées en coopération ;
- (3) Le niveau macro concerne les objectifs qui expliquent les interactions entre chaque groupe et l'environnement.

En principe, un état fusionné est conçu comme l'**état centroïde**. Au temps t , la position du groupe $p_{x,y,t}^c$ de l'état centroïde s_t^c se calcule par la moyenne des positions $p_{x,y,t}^{a^i}$ de chaque agent a^i (à la position (x, y)) du groupe c . L'équation suivante correspond à ce dernier calcul. L'état centroïde s_t^c inclut toutes informations requises des agents (au minimum la position et la vitesse) et produit le même procédé pour obtenir la valeur de chaque variable continue.

$$p_{x,y,t}^c = \frac{\sum_{i=1}^{|c|} p_{x,y,t}^{a^i}}{|c|} \quad (5.1)$$

Néanmoins, notre état fusionné ne comporte pas uniquement des variables continues. De manière formelle, un **état fusionné** représente l'état canonique d'un groupe basé sur un vecteur de variables tout comme celui de l'état d'un agent. Pour chaque variable de ce vecteur, sa valeur est calculée en fusionnant les valeurs de cette même variable appartenant aux membres du groupe. Toutes valeurs continues (telle que la position, la vitesse,...) ou certaines finies (telle que l'orientation) peuvent être fusionnés en utilisant leur moyenne. Cependant, cette méthode est inapplicable pour des valeurs qualitatives, telles que l'état émotionnel (en colère, en cris, en panique,...) ou la configuration du groupe (en cercle, en ligne, en

colonne, en V,...). Pour cette raison, une ontologie peut être définie pour indiquer la méthode de fusion à utiliser selon les propriétés de la variable.

Un état fusionné formalise un état de groupe avec un nombre non spécifique de membres. Ainsi si un état observable d'un membre est fortement soumis à l'imprécision et l'incertitude, l'état fusionné qui l'inclura n'en sera qu'affecté qu'au $1/n$ (n étant le nombre de membres du groupe). Non seulement cette approche réduit le bruit des observations, mais elle nous permet de réduire la complexité d'observation d'une scène de foule, puisqu'il est plus simple de suivre chaque groupe que chaque individu.

La séquence de ces états fusionnés caractérise le comportement du groupe. Le comportement peut ainsi être appris et reconnu en utilisant l'approche HMM, achevant la détection de comportement de groupe. Notre modèle présente cependant un point innovant qui consiste à utiliser des séquences d'états relatifs discrétisés pour formaliser et détecter des comportements de groupes. En effet, comme l'a démontré notre état de l'art, les méthodes de reconnaissance de groupe sont limitées. Notre ajout du *pourquoi* dans les états de groupe produisant des états relatifs, nous permet d'extraire les groupes qui ont les mêmes comportements relatifs par rapport aux autres entités de la situation. La partie suivante sur les expérimentations le démontrera en termes de résultat.

5.1.2 État relatif discrétisé d'un groupe envers un objectif

Afin de calculer un **état relatif discrétisé** (*discrete relative state*, DR) comme dans la Figure 5.1, nous utilisons les observations $\{o_t^{a^i}, o_t^{g^j}\}$ des états cachés $\{s_t^{a^i}, s_t^{g^j}\}$ pour chaque agent a^i du groupe c et chaque objectif (*goal*) $g^j \notin c$ (pouvant être mobile) de l'instant 0 à t . Chaque o_t et s_t contiennent la position et la vitesse $\langle p_t, v_t \rangle$. Le processus de calcul se décompose en trois étapes.

1. Nous calculons $\{s_{t-1}^c, s_t^c\}$ les **états fusionnés** à l'instant $t-1$ et t d'un groupe c en utilisant l'équation 5.1.
2. Nous calculons les **états relatifs** $\{\Delta s_{t-1}^{c,g}, \Delta s_t^{c,g}\}$ sur la différence des états fusionnés $\{s_{t-1}^c, s_t^c\}$ du groupe envers les états des objectifs $\{s_{t-1}^g, s_t^g\}$. La variable relative $\Delta r_t^{c,g} \in \Delta s_t^{c,g}$ est donnée par :

$$\Delta r_t^{c,g} = \sqrt{|r_{x,t}^c - r_{x,t}^g|^2 + |r_{y,t}^c - r_{y,t}^g|^2} \quad (5.2)$$

où $r_{x,y,t}$ est une variable continue (comme $p_{x,y,t}$ de l'équation 5.1). La position relative et la vitesse relative sont deux exemples de variables relatives d'une entité envers une seconde. Pour illustrer une notion importante des états relatifs, considérons la position et les coordonnées géographiques entre deux entités A et B . La position relative d'une entité envers l'autre est la distance. Cependant, si les coordonnées géographiques de A est *au nord de B*, et B est *au sud de A*, alors l'état relatif de A envers B sera différent de l'état relatif de B envers A . Une fois encore, tout calcul de fusion dépend du type de la variable, qu'elle soit continue, finie ou discrète. Une ontologie est aussi à utiliser pour définir quelle méthode peut être appliquée selon les propriétés de chaque variable.

3. Nous **discrétisons** les états relatifs $\{\Delta s_{t-1}^{c,g}, \Delta s_t^{c,g}\}$ sur leur différence de $t-1$ à t pour chaque variable $\Delta r^{c,g} \in \Delta s^{c,g}$. Les variables DR (relatives discrétisées) $\{dr_n, dr_d, dr_c, dr_i\}$ sont introduites pour représenter tout état DR et représentent respectivement les tendances suivantes : nulle (n), décroissante (d), constante (c) et croissante (i). Ces variables DR sont données par :

dr_n (est nulle)		$\Delta r_t^{c,g} < \delta r_{min}$
dr_d (diminue)	si seulement si	$\Delta r_t^{c,g} < \Delta r_{t-1}^{c,g} - \delta r_{min}$
dr_i (augmente)		$\Delta r_t^{c,g} > \Delta r_{t-1}^{c,g} + \delta r_{min}$
dr_c (est constant)		$ \Delta r_t^{c,g} - \Delta r_{t-1}^{c,g} < \delta r_{min}$

La valeur δr_{min} indique une transition minimale d'état entre deux instants successifs en fonction de la variable $r \in s$. Ainsi elle est directement proportionnelle avec le nombre d'observations obtenues par seconde. Si chaque observation inclut la position p et la vitesse v , alors l'état DR (d'un groupe envers un objectif de $t - 1$ à t) inclut une position DR parmi $\{p_n, p_d, p_c, p_i\}$ et une vitesse DR parmi $\{v_n, v_d, v_c, v_i\}$. Il en résulte **l'ensemble des états DR** suivant qui représentent toutes les possibles tendances de la position et de la vitesse :

$$Q^{DR} = \left\{ \begin{array}{cccc} \langle p_n, v_n \rangle & \langle p_n, v_d \rangle & \langle p_n, v_i \rangle & \langle p_n, v_c \rangle \\ \langle p_d, v_n \rangle & \langle p_d, v_d \rangle & \langle p_d, v_i \rangle & \langle p_d, v_c \rangle \\ \langle p_i, v_n \rangle & \langle p_i, v_d \rangle & \langle p_i, v_i \rangle & \langle p_i, v_c \rangle \\ \langle p_c, v_n \rangle & \langle p_c, v_d \rangle & \langle p_c, v_i \rangle & \langle p_c, v_c \rangle \end{array} \right\}$$

L'avantage que Q l'ensemble des états ait un domaine discrétisé facilite l'apprentissage du modèle HMM, de même que la lecture de chaque état *human-readable* (i.e. compris par un non-expert). En exemple, l'état DR $\langle p_n, v_n \rangle$ représente une position relative discrétisée nulle p_n et une vitesse relative discrétisée nulle v_n (i.e. la position et la vitesse du groupe sont équivalente à ceux de l'objectif) de $t - 1$ à t .




FIGURE 5.1 – Le processus pour calculer un état relatif discrétisé à partir d'un ensemble d'états observables de n agents d'un groupe c et d'un objectif g

Le schéma 5.1 représente notre processus de calcul d'un état DR par notre approche *bottom-up*. Il est à voir comment une séquence d'états DR permet de comprendre le *pourquoi* d'un comportement observé.

5.1.3 Séquencement d'un comportement objectivé par des états relatifs discrétisés

L'explication de séquences simples de comportements relatifs nous fournit une preuve de l'utilité de ces nouveaux états.

Dans une séquence d'état DR, nous pouvons lire le mouvement relatif d'un groupe envers un objectif. Par exemple, les trois séquences d'états DR suivantes nous illustrent une séquence de trois différents **comportements objectivés de groupe** :

$$\Delta S_{0,4}^{c,g} = \{\langle p_n, v_n \rangle, \langle p_n, v_i \rangle, \langle p_i, v_i \rangle, \langle p_i, v_c \rangle, \langle p_i, v_c \rangle\}$$

$$\Delta S_{5,9}^{c,g} = \{\langle p_c, v_d \rangle, \langle p_c, v_i \rangle, \langle p_c, v_c \rangle, \langle p_c, v_c \rangle, \langle p_c, v_d \rangle\}$$

$$\Delta S_{10,14}^{c,g} = \{\langle p_d, v_c \rangle, \langle p_d, v_c \rangle, \langle p_d, v_d \rangle, \langle p_n, v_d \rangle, \langle p_n, v_n \rangle\}$$

Durant la première partie $\Delta S_{0,4}^{c,g}$, le comportement décrit est celui du groupe c envers l'objectif g , dans lequel le groupe se met en mouvement et s'en éloigne à vitesse constante. Pour la seconde partie $\Delta S_{5,9}^{c,g}$, c contourne g à une distance et une vitesse constantes (i.e. il tourne autour). La dernière partie $\Delta S_{8,12}^{c,g}$ illustre c ayant changé de direction pour se rendre à g et s'y arrête une fois atteint.

Notre observation qu'une séquence de ces états DR nous apparaît comme une séquence de comportements simples (bas niveaux) appartenant à un comportement plus complexe (haut niveau). Nous retrouvons ici le principe d'un comportement **hiérarchisé** dans le niveau **méso** d'observation. Si nous reprenons notre exemple ci-dessus, que le groupe c soit une équipe de sécurité et l'objectif g soit une infrastructure critique, alors le comportement complexe peut tout à fait être le mouvement d'un tour de garde autour de l'infrastructure critique dont il protège l'entrée. Chaque comportement objectivé de groupe exécute de manière **récurrente** les mêmes séquences d'états DR et un HMM s'utilise pour les apprendre et les reconnaître.

Une fois ce processus, pour calculer les états relatifs, effectué sur les données d'observations des entités de la situation asymétrique surveillée, il nous faut identifier les groupes avant de tenter de reconnaître les comportements objectivés de groupe.

5.2 Identification des groupes

L'identification d'un groupe que nous proposons peut s'effectuer de deux manières déjà connues (i.e. section 2.2.1 page 41), mais en utilisant notre innovation des états relatifs :

- ▷ Un algorithme *bottom-up* fusionne en une entité (un groupe) les paires d'agents les plus proches par proxémie (page 19) et dont nous observons les mêmes séquences d'états relatifs ;
- ▷ Un algorithme *top-down* qui segmente la foule en groupes par la **proxémie** et quand l'utilité du groupe est plus haute lorsqu'un sous-groupe est absent du groupe, sachant que cette utilité se calcule sur leurs états relatifs.

La méthode, qui est utilisée, doit être exécutée à chaque nouvelle observation de la situation, afin de recalculer les groupes qui ont un nombre variable de membres au cours du temps. Une fois la méthode exécutée, les états fusionnés (passés et présents) des groupes sont aussi mis à jour.

Nous avons besoin d'une excellente précision, puisque nous utilisons ces groupes identifiés pour reconnaître leurs comportements collectifs et leurs objectifs. L'état de l'art pour la reconnaissance de groupe par un HMM démontre une possibilité de l'effectuer en se basant sur des informations telles que la position, la vitesse et l'orientation des membres, et ceci en fonction de l'environnement surveillé. Le défaut de ses méthodes est de compter sur une orientation linéaire pour comprendre quand des groupes se rejoignent, se croisent et se séparent. La réalité tend à prouver que les orientations sont fortement perturbées par les tentatives d'évitement d'agents à agents. Ces perturbations génèrent la détection d'une grande quantité de faux positifs et de vrais négatifs (i.e. une détection de groupes dont les membres ne sont pas à 100% réellement membres et une absence de détection de groupes qui pourtant existent réellement).

La solution que nous proposons est liée à notre **interprétation** des comportements des groupes. Notre point de vue est que chaque membre d'un groupe exécute les mêmes comportements relatifs envers les autres entités de la situation. Nous fusionnons dans un même groupe tous les agents ayant des séquences d'états relatifs discrétisés équivalentes. Il s'agit d'une opération de fusion par une fonction de similarité.

5.2.1 Micro → Méso - Approche par la proxémie et les séquences d'états relatifs

Nous avons produit l'algorithme 2 qui compare, pour chaque objectif, les séquences d'états DR de chaque paire de groupes (initialement contenant un agent). Il retourne les groupes d'agents dont les membres ont des séquences d'observations équivalentes. Les plus récentes observations ont plus d'impact que les anciennes de manière à ce que les groupes qui fusionnent ou se séparent soient plus rapidement pris en compte, mais que ceux qui ne font que se croiser sont correctement identifiés par les anciennes observations.

Afin de déterminer si deux séquences d'états DR sont proches (ligne 14 et 15 de l'algorithme 2) : une récompense (points, poids,...) est donnée pour chaque égalité, équivalence, distance ou différence entre chaque paire d'états (proches dans le temps). Nous pouvons reprendre l'exemple de "[Hiérarchie à base de grammaires stochastiques](#)" (page 67) avec les algorithmes MDL et DI. Si la somme des récompenses est plus haute qu'un seuil, alors nous considérons que les séquences sont équivalentes. Chaque récompense peut être définie par un apprentissage automatique ou manuellement par l'utilisateur, en fonction des propriétés des entités et de la situation observée. Plus l'état est ancien, plus la récompense doit être petite, de manière à ce que les plus récents états aient le plus d'impact sur la détection de groupe. Cette récompense et ce seuil peuvent être enregistrés dans une ontologie en fonction des propriétés des variables.

De manière à accélérer l'exécution de cet algorithme, nous pouvons :

- trier la liste des paires selon la proxémie (i.e. *trierParProxemie(listeGroupes)*) où en priorité, les paires ayant une distance de groupe) : Les plus probables paires de groupes sont rapidement agréées, ce qui diminue le nombre de paires à tester ;
- filtrer la liste de paires en retirant les paires où la distance entre une paire de groupes est plus grande qu'une limite prédéfinie (telle que par la proxémie) : Il y a un risque de séparer un réel groupe observable si ce seuil choisi est trop petit ;

Algorithme 2 : Identification des groupes d'agents par une approche *bottom-up*.

Data : $listeAgents \neq \emptyset$ // la liste de toutes les entités observées de la situation surveillée;

```

1 begin
2    $listeObjectifs \leftarrow listeAgents$  // la liste des objectifs peut être tout agent;
3    $listeGroupes \leftarrow \emptyset$  // la liste des groupes est initialement vide;
4   for  $agent \in listeAgents$  do
5      $listeGroupes \leftarrow listeGroupes \cup \{agent\}$  // chaque agent forme son propre groupe;
6    $feedback \leftarrow true$  // tant qu'il y a une mise à jour de la liste des groupes;
7   while  $feedback$  do
8      $feedback \leftarrow false$ ;
9      $listeGroupes \leftarrow trierParProxemie(listeGroupes)$ ;
10    for  $groupe1, groupe2 \in listeGroupes, groupe1 \neq groupe2$  do
11       $valeur \leftarrow 1.0$ ;
12       $valeurMax \leftarrow 1.0$ ;
13      for  $goal \in listeObjectifs$  do
14        for  $t := 0 \rightarrow T_{actuel}$  do
15          if  $etatDR(t, groupe1, goal) = etatDR(t, groupe2, goal)$  then
16             $valeur \leftarrow valeur + t$  // ainsi plus l'état est récent et plus il a d'impact ;
17             $valeurMax \leftarrow valeurMax + t$  // pour mettre à jour plus rapidement ;
18          if  $valeur/valeurMax > valeurMin$  then
19            //  $valeurMin$  est la valeur seuil pour les considérer comme un seul groupe ;
20             $groupe \leftarrow groupe1 \cup groupe2$ ;
21             $listeGroupes \leftarrow \{groupe\} \cup listeGroupes \setminus \{groupe1, groupe2\}$ ;
22             $feedback \leftarrow true$ ;
23            break;
24 end
25 return  $listeGroupes$ 

```

- exécuter les itérations en parallèle pour chaque paire de groupe qui n'est pas déjà en train d'être testée : le temps requis de calcul est divisé par le nombre possible d'itérations en parallèle ;
- réduire la longueur des séquences DR en ne gardant que les plus récents états DR : plus la séquence est petite, plus rapidement les variables des états sont mises à jour ; De même, plus les récentes observations sont incertaines, plus la précision de détection des groupes est réduite ;
- discrétiser les variables : le domaine d'une variable discrétisée réduit la complexité ;

Un avantage d'utiliser les comportements relatifs (et pas seulement l'historique de leur proxémie) est de pouvoir identifier des groupes d'individus qui peuvent être séparés par une certaine distance, mais continuent de suivre les mêmes comportements objectivés. Par exemple, si plusieurs individus d'une équipe sont séparés de plusieurs mètres, qu'ils ne suivent pas les mouvements des autres groupes de la foule, qu'ils se dirigent / contournent / s'éloignent des mêmes choses (tels que les forces de sécurité, des obstacles, une infrastructure critique), alors l'algorithme les détectera. Pourtant l'œil d'un expert en est souvent incapable. Nous avons ici un algorithme tout à fait intéressant, puisqu'il est capable d'identifier les groupes ayant un comportement anormal parmi une foule dans un environnement asymétrique.

5.2.2 Macro → Méso - Approche par la proximité et l'utilité de groupe

Algorithme 3 : Identification des groupes d'agents par une approche *top-down*.

Data : $listeAgents \neq \emptyset$ // la liste de toutes les entités observées de la situation surveillée;

```

1 begin
2    $listeGroupes \leftarrow \emptyset$ ;
3    $groupe \leftarrow \{listeAgents\}$  // initialement toute la foule dans un seul groupe;
4    $feedbackNewGroupe \leftarrow true$ ;
5   while  $feedbackNewGroupe$  do
6      $sous_groupe \leftarrow \emptyset$ ;
7      $groupe \leftarrow trierParProxemie(groupe)$ ;
8      $feedbackDecouperGroupe \leftarrow true$ ;
9     while  $feedbackDecouperGroupe$  do
10       $feedbackDecouperGroupe \leftarrow false$ ;
11       $utilityGroupe \leftarrow calculUtility(groupe)$  // utilité calculée du groupe;
12      for  $agent \in groupe$  do
13        if  $utilityGroupe < calculUtility(groupe \setminus \{agent\})$  then
14           $feedbackDecouperGroupe \leftarrow true$ ;
15           $sous_groupe \leftarrow sous_groupe \cup agent$ ;
16           $groupe \leftarrow groupe \setminus \{agent\}$ ;
17          break;
18       $listeGroupes \leftarrow listeGroupes \cup \{groupe\}$ ;
19       $feedbackNewGroupe \leftarrow false$ ;
20      if  $|sous_groupe| > 1$  then
21         $groupe \leftarrow sous_groupe$ ;
22         $feedbackNewGroupe \leftarrow true$ ;
23      if  $|sous_groupe| = 1$  then
24         $listeGroupes \leftarrow listeGroupes \cup \{sous_groupe\}$ ;
25 end
26 return  $listeGroupes$ 

```

Nous avons produit l'algorithme 3 qui retire un sous-groupe d'un groupe quand ce groupe est calculé avec une plus grande utilité lorsque ce sous-groupe en est absent. Initialement, le groupe est la foule complète. Pour ce processus, l'utilité du groupe est calculée, ainsi qu'avec chaque possible retrait d'un membre. Lorsque l'utilité augmente à chaque retrait d'un membre, alors le membre est retiré et placé dans le sous-groupe. Le processus recommence sur le sous-groupe jusqu'à obtenir l'ensemble des (sous-)groupes de la foule qui ont chacun la plus grande utilité possible.

L'utilité d'un groupe se calcule sur la récompense qu'il obtient lorsque chaque membre exécute les mêmes comportements relatifs à chaque objectif de la situation. En d'autres termes, à partir d'un groupe, l'algorithme retire le sous-groupe qui n'est pas **coopératif** par le calcul d'une utilité basée sur la **synergie**.

Soit :

- (1) Une fonction de récompense R qui donne la **récompense** d'une entité à propos de son comportement et de son objectif, e.g. $R^{\alpha^i}(\lambda^h, g^j)$ représente la récompense quand l'agent α^i est en train d'exécuter

le comportement λ^h en fonction de l'objectif g^j .

- (2) Une fonction d'utilité U donne l'**utilité** d'une entité en fonction de la probabilité estimée de chaque possible paire de comportements et d'objectifs, e.g. :

$$U_t(\alpha^i) = \sum_{\forall \lambda^h \in \Lambda} \sum_{\forall g^j \in G} R^{\alpha^i}(\lambda^h, g^j) \times M_t^{\alpha^i}(\lambda^h, g^j) \quad (5.3)$$

est l'utilité d'une entité α^i en fonction du **comportement objectif** estimé et de la fonction récompense. De cette manière, le système prendra en compte non seulement le comportement objectif ayant la plus haute probabilité de détection, mais aussi son incertitude en réduisant la récompense par sa probabilité de détection.

- (3) L'**utilité de groupe** $U_t(C)$ qui donne l'utilité du groupe C selon son *comportement objectif de groupe* par l'approche *top-down* :

$$U_t(C) = \sum_{\forall \lambda^h \in \Lambda} \sum_{\forall g^j \in G} R^C(\lambda^h, g^j) \times M_t^C(\lambda^h, g^j) \quad (5.4)$$

i.e. nous calculons à partir d'une entité qui représente le groupe afin de réduire la complexité $O(|\Lambda| \times |G|)$ du calcul (où l'approche *bottom-up* serait $O(|C| \times |\Lambda| \times |G|)$).

Si $U_t(C) < U_t(C \setminus \{\alpha^i\})$ alors nous considérons que l'agent α^i est **non coopératif** avec le groupe C , puisque l'**utilité de groupe** est plus haute quand l'agent α^i est retiré du groupe C .

Nous voulons découvrir **les groupes non coopératifs** parmi la foule C . Ainsi, par l'approche *top-down*, nous appliquons les étapes suivantes de l'algorithme 3 :

1. Nous calculons l'**utilité de groupe** $U_t(C^0)$ (où initialement le C^0 est la foule complète C) ;
2. Pour chaque agent α^i du groupe C , nous calculons $U_t(C^0 \setminus \{\alpha^i\})$;
3. Nous retirons chaque agent α^i de la foule C^0 qui permet l'obtention d'une utilité plus grande du groupe $U_t(C^0)$ et nous les plaçons dans le groupe suivant C^1 ;
4. Nous répétons le même processus (de 1. à 3.) pour le groupe suivant C^1 et ainsi de suite, jusqu'à obtenir les groupes $\{C^0, C^1, \dots, C^n\}$ parmi la foule C qui ne sont pas coopératifs entre eux-mêmes ;

Dans le cas où $U_t(C) < U_t(C \cup \{\alpha^i\})$, alors nous considérons que l'agent α^i est **coopératif** avec le groupe C , puisque l'*utilité de groupe* est plus haute quand l'agent α^i est ajouté dans le groupe C . Ainsi, notre processus pourrait être obtenu par une approche *bottom-up*, telle que les étapes suivantes qui agrègent pour découvrir **les groupes non coopératifs** parmi la foule C :

1. Chaque agent α^i est initialement dans son propre groupe C^i seul ;
2. Nous calculons $U_t(C^i \cup C^j)$ pour chaque possible paire de C^i et C^j ;
3. Nous fusionnons les deux groupes C^i et C^j qui donnent la plus grande valeur d'utilité de groupe ;
4. Nous répétons les étapes 2. et 3. aussi longtemps que des groupes continuent à être fusionnés afin d'obtenir la liste de groupes $\{C^0, C^1, \dots, C^m\}$ où chaque membre d'un groupe est coopératif avec les autres membres.

La question serait "quand l'approche *top-down* ou *bottom-up* est elle la meilleure à appliquer afin de découvrir les groupes non coopératifs parmi une foule ?". L'approche *top-down* est la plus appropriée quand il y a un petit nombre de groupes incluant un grand nombre de membres, et inversement l'approche *bottom-up* (i.e. un grand nombre de groupe incluant un petit nombre de membres) est plus appropriée. Des expériences permettraient de confirmer cette intuition.

Dans l'état de l'art, la principale manière de découvrir les groupes parmi une foule est de fusionner les individus en groupes quand ils ont des objectifs ou des comportements perçus comme très proches. Toutefois, notre approche utilise les deux par leurs comportements objectivés. Contrairement à la réalité où un expert éprouverait une difficulté croissante avec le nombre de personnes et de variables observables, notre innovation des états relatifs nous permet de détecter les groupes non coopératifs, quels que soient la taille, le comportement et l'objectif de chaque groupe.

Le point le plus intéressant est que cette détection des groupes n'a besoin que de l'observation des positions et vitesses des agents (qui s'obtiennent de n'importe quel système de surveillance). Notre objectif principal était de pouvoir déterminer les agents qui agissent de manière corrélée. Notre innovation des états relatifs nous permet de comparer les comportements variés des agents et d'en extraire les groupes. De par le fait de regrouper les agents ayant les mêmes comportements individuels et objectifs, cette approche nous facilite la détection des comportements collectifs des groupes et de leurs objectifs.

5.3 Assignment des comportements objectivés aux groupes

Notre algorithme suivant nous est utile pour obtenir les groupes et leurs objectifs parmi les agents observés. La probabilité que chaque groupe soit en train d'exécuter chaque comportement collectif en fonction de chaque objectif possible est établie en fonction de séquences d'observations (sur les membres des groupes et les objectifs) et de modèles appris de comportements collectifs objectivés.

Afin de produire une **détection des comportements objectivés de groupe**, nous avons besoin du 3-uplet $\langle O_t^{c,G}, \Lambda, F \rangle$ où :

$O_t^{c,G} = \left\{ \left\{ \{o_0^{a^1}, o_0^{a^2}, \dots, o_0^{a^{|c|}}, o_0^{g^1}, \dots, o_0^{g^{|G|}}\}, \dots, \{o_t^{a^1}, \dots, o_t^{g^{|G|}}\} \right\} \right\}$ inclus la séquence d'observations de

chaque agent du groupe c et de chaque objectif de G de l'instant initial 0 à t actuel, où $\{o_t^{a^i}, o_t^{g^j}\}$ est une observation du $i^{\text{ème}}$ agent d'un groupe observé c pouvant exécuter un comportement relatif au $j^{\text{ème}}$ objectif ;

Λ est un ensemble de HMMs, où $\lambda^h \in \Lambda$ est le HMM modélisant le $h^{\text{ème}}$ comportement objectivé de groupe ;

F est un ensemble de fonctions, où f^h est une fonction (i.e. section 5.1.2 page 92) qui calcule ΔS_t^h la **séquence d'états relatifs discrétisés (DR)** à partir d'une séquence d'observations en fonction du HMM λ^h . Ce dernier point est uniquement dans le cas où l'ensemble des HMMs n'ont pas le même ensemble d'états (e.g. basé sur des variables différentes), sinon une unique fonction f sera commune à tous.

Pour rappel (i.e. section 3.2.1 page 55), $Pr(\lambda|O_t)$ est la probabilité que le comportement λ est exécuté durant la séquence d'observations O_t . Durant les dernières T observations (afin de capturer le récent comportement), le calcul d'une séquence d'observations $O_{t-T,t}^{c,g^j}$ en la séquence d'états DR

$\Delta S_{t-T,t}^{c,g^j}$ correspondante est donnée par :

$$M_t^c(\lambda^h, g^j) = Pr \left(\lambda^h \mid \Delta S_{t-T,t}^{c,g^j} = f^h(O_{t-T,t}^{c,g^j}) \right) \quad (5.5)$$

Pour chaque comportement de groupe λ^h et chaque objectif possible g^j , nous calculons la probabilité (par l'équation 5.5) qu'un groupe c soit en train d'exécuter λ^h en fonction de l'objectif g^j . Le résultat nous donne l'ensemble suivant (rangé en ligne pour chaque comportement et en colonne pour chaque objectif) :

$$M_t^c = \left\{ \begin{array}{ccccc} M(\lambda^1, g^1) & \cdots & M(\lambda^1, g^j) & \cdots & M(\lambda^1, g^{|G|}) \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ M(\lambda^h, g^1) & \cdots & M(\lambda^h, g^j) & \cdots & M(\lambda^h, g^{|G|}) \\ \vdots & \ddots & \vdots & \ddots & \vdots \\ M(\lambda^{|\Lambda|}, g^1) & \cdots & M(\lambda^{|\Lambda|}, g^j) & \cdots & M(\lambda^{|\Lambda|}, g^{|G|}) \end{array} \right\}$$

Nous obtenons la paire la plus probable (i.e. le comportement et l'objectif) $\langle \lambda^H, g^L \rangle$ par :

$$M(c, t) = \arg \max_{\forall \lambda^h \in \Lambda} \left\{ M_t^c(\lambda^h, g^j) \right\}_{\forall g^j \in G} \quad (5.6)$$

Dans ce cas, seulement un **comportement objectif de groupe** est sélectionné pour le groupe par la meilleure probabilité de M_t^c . Cependant, un groupe peut exécuter différents comportements pour différents objectifs au même moment. Nous obtenons λ^H le comportement le plus probable pour chaque objectif $\forall g^j \in G$ par le résultat de :

$$M(c, g^j, t) = \arg \max_{\forall \lambda^h \in \Lambda} \left\{ M_t^c(\lambda^h, g^j) \right\} \quad (5.7)$$

De la même manière, pour un autre cas d'utilisation, pour un groupe, nous pouvons obtenir $M(c, \lambda^i, t)$ l'objectif g^h le plus probable pour chaque comportement λ^i de M_t^c .

Afin d'obtenir une probabilité sur les récents comportements des agents, nous n'utilisons que les dernières T observations. Les expériences de la Partie suivante montreront l'impact sur la détection de la qualité quand la longueur T de la séquence d'observation est modifiée pour l'apprentissage et pour la reconnaissance.

Pour résumer ce point, suivant les instructions de cette section, nous modélisons un **comportement objectif de groupe** (*goal-based group behavior*) en utilisant des séquences d'**états relatifs discrétisés** calculés à partir de séquences d'observations des groupes surveillés d'agents et de leurs possibles objectifs. La section suivante présente notre méthode pour extraire des intentions spécifiques qui seraient responsables des séquences de comportements observés des groupes.

5.4 Estimation des intentions

Nous allons nous servir de la section précédente afin de déterminer l'intention (i.e. l'objectif à long terme) d'un groupe. L'intention d'un groupe est présentée ici comme une agrégation évaluée sur un

(ensemble de) comportement(s) objectivé(s) d'un groupe par à un objectif (une entité ou un ensemble d'entités).

5.4.1 Intentions par l'évaluation des comportements objectivés sur le long terme

Dans une situation surveillée comportant de nombreux objectifs possibles pour un groupe, nous détectons les actuels comportements objectivés de groupe. Afin de détecter si le groupe est en train d'exécuter une séquence de comportements en fonction d'une intention particulière, nous mesurons une valeur selon le processus suivant que nous appelons la **détection de comportements objectivés évalués de groupe** (*Valued Goal-based Group Behavior Detection*).

Cette valeur peut être mesurée en fonction du type de l'**intention** que nous cherchons à détecter. De l'instant $t - T$ à t , nous utilisons les **intentions évaluées** suivantes afin de représenter :

- $V_{t-T,t}^{c^i, g^j}$ l'**intention** du groupe c^i selon l'objectif g^j ;
- $V_{t-T,t}^{c^i, G^j}$ l'**intention** du groupe c^i selon l'ensemble d'objectifs G^j ($\in G$, e.g. : toutes les forces de sécurité, les infrastructures critiques, les zones sécurisées et dangereuses,...) ;
- $V_{t-T,t}^{C^i, g^j}$ l'**intention** d'un ensemble de groupes C^i selon l'objectif g^j .

En vue de mesurer cette intention évaluée, nous utilisons une distribution dans laquelle un objectif g et un comportement objectivé λ^h d'un groupe c nous donnera la valeur $V(c, g, \lambda^h)$. Une distribution est créée en fonction de l'intention ϕ^p ($\in \Phi$ l'ensemble définit des intentions) que nous désirons détecter par l'analyse de la séquence de comportements objectivés de groupe. L'avantage d'une telle distribution est qu'elle peut être créée manuellement ou apprise automatiquement afin de détecter chaque type d'intention requis. Ainsi, les équations pour évaluer les trois précédents types d'intentions sont :

$$V_{t-T,t}^{\phi^p, c^i, g^j} = \sum_{t_c=t-T}^t V^{\phi^p} (c^i, g^j, \lambda^h = M(c^i, g^j, t_c)) \quad (5.8)$$

$$V_{t-T,t}^{\phi^p, c^i, G^j} = \sum_{g^l \in G^j} V_{t-T,t}^{\phi^p, c^i, g^l} \quad (5.9)$$

$$V_{t-T,t}^{\phi^p, C^i, g^j} = \sum_{c^l \in C^i} V_{t-T,t}^{\phi^p, c^l, g^j} \quad (5.10)$$

Comme exemple de cas d'utilisation, il est possible de détecter des civils ayant une intention dangereuse ϕ^p envers eux-mêmes : la distribution donne une valeur positive quand des civils se déplacent en direction d'une zone sécurisée et une valeur négative quand les groupes se dirigent vers une zone dangereuse. Tout groupe qui est en train d'exécuter ϕ^p aura une valeur d'intention positivement grande. Selon la distribution de l'intention $\phi^p \in \Phi$, l'intention peut être évaluée sur le fait que le groupe c est en train de se diriger vers un objectif $g^{\phi^p, c}$ sur le long terme par :

$$g_{t-T,t}^{\phi^p, c} = \arg \max_{\forall g^j \in G} \left\{ V_{t-T,t}^{\phi^p, c, g^j} \right\} \quad (5.11)$$

Dans la situation surveillée et ce que nous cherchons à identifier, un **comportement objectivé évalué de groupe** indique l'**intention du groupe** sur le long terme sur deux niveaux d'observations : (1) une

information générale à propos de son objectif spécifique, et (2) si son intention est normale (i.e. ami) ou déviante (*foe*, i.e. ennemi). Notre capacité à apprendre et à reconnaître les comportements objectivés évalués de groupe en utilisant l'approche HMM en temps réel est démontrée dans la Partie suivante sur les expérimentations.

5.4.2 Intentions par les états objectivés discrétisés

Dans l'état de l'art sur "[Comportements déviants \(anormaux, inattendus et suspicieux\)](#)" page 48, nous avons dévoilé l'utilité d'identifier de tels comportements. Nous proposons ici une nouvelle discrétisation appliquée aux objectifs, afin d'identifier si l'intention de groupe est normale ou déviante. Pour exemple, nous pouvons suspecter une intention malveillante (i.e. déviante) quand un groupe contourne les forces de sécurité et se dirige constamment vers une infrastructure critique.

Comme nous l'avons présenté dans la section 5.1.2 page 92, l'algorithme *Baum-Welch* est capable d'apprendre un comportement objectivé de groupe dans un HMM. Celui-ci se base sur un ensemble d'états relatifs discrétisés calculé à partir d'observations des agents et des objectifs. Dès lors, il nous est possible d'apprendre une intention en utilisant un ensemble de séquences de comportements comme états. Nous rajoutons ainsi un niveau d'observation supérieur à celui atteint jusqu'à présent.

En utilisant une séquence d'états où chaque état serait un comportement objectivé, il est possible d'apprendre et de reconnaître un comportement sur le long terme (dans un plus haut niveau méso d'observation). Toutefois, cela n'est pas suffisant pour identifier si ce comportement long terme inclut une intention malveillante (ou simplement déviante). Pour cela, il nous manque une information à propos du type de l'objectif dans l'ensemble des états. Nous allons y ajouter la discrétisation de l'objectif, comme les exemples indiqués dans le tableau 5.1.

Symboles	Les objectifs discrétisés de G
G^+	- Les objectifs positifs : les forces de sécurité, les zones sécurisées,...
G^-	- Les objectifs négatifs : les infrastructures critiques, les zones dangereuses, les positions défensives,...
G^0	- Les autres objectifs : tous les autres types neutres.
Les comportements objectivés de groupe de Λ	
$\lambda^{c \rightarrow g}$	Le groupe c est en train de se diriger vers g
$\lambda^{c \odot g}$	Le groupe c est en train de contourner g
$\lambda^{c \leftarrow g}$	Le groupe c est en train de s'éloigner de g
$\lambda^{c \leftrightarrow g}$	Le groupe c n'a pas un mouvement relatif différent de celui de g
$\lambda^{c \rightsquigarrow g}$	Les autres mouvements (s'ils existent)

TABLEAU 5.1 – Des symboles décrivant des comportements objectivés de groupes en fonction du type d'objectifs

Le tableau 5.1 présente l'ensemble de symboles d'un possible comportement objectivé de groupe en se basant sur deux variables toujours facilement obtenues d'un système de surveillance : la position et la vitesse. Le symbole $\lambda^{C \rightsquigarrow g}$ représente un HMM par défaut (sans apprentissage) et sera utilisé si seulement si tous les autres HMM appris nous donnent des probabilités plus faibles. Dans le cas où cela

l'ensemble d'intentions apprises) est obtenue par :

$$\phi^H = \arg \max_{\forall \phi^h \in \Phi} \left\{ Pr \left(\phi^h \mid \Delta S_{t-T,t}^{c,G^+,G^0,G^-} = f^h(\Lambda_{t-T,t}^{c,G}) \right) \right\} \quad (5.14)$$

où $\Delta S_{t-T,t}^{c,G^+,G^0,G^-}$ est la **séquence d'états objectivés discrétisés** calculée à partir des **séquences de comportements objectivés de groupe** $\Lambda_{t-T,t}^{c,G}$ du groupe C et de tous les objectifs de G de l'instant $t - T$ à t actuel.

A ce niveau **méso** d'observation, nous sommes arrivés au plus haut niveau d'**évaluation de la situation** (asymétrique). La partie suivante montrera l'expérimentation d'une telle évaluation.

5.5 Conclusion

En utilisant un ensemble de séquences d'observations d'agents d'une foule et d'objectifs de situations asymétriques, incluant des intentions normales et déviantes (anormales, malveillantes,...), notre méthode calcule une observation du niveau micro à méso suivant le processus :

- (1) l'**état relatif** d'un agent envers un objectif (une entité de la situation) à partir de deux observations consécutives de l'agent et de l'objectif ;
- (2) le **comportement relatif** qu'un agent est en train d'exécuter envers un objectif à partir d'une séquence d'états relatifs ;
- (3) les **groupes** dont les membres ont des comportements relatifs équivalents à partir de leurs séquences d'états relatifs ;
- (4) l'**état fusionné** de groupe qui fusionne les informations actuelles des membres en une seule entité afin de fortement réduire la complexité de la surveillance de foule.
- (5) les **comportements objectivés de groupe** à partir de leurs séquences d'états relatifs discrétisés, basé sur le comportement relatif de l'état fusionné du groupe envers l'état de l'objectif ;
- (6) les **états objectivés discrétisés** à partir de la détection de leurs comportements objectivés de groupe et des types d'objectifs discrétisés : positifs, neutre et négatifs.
- (7) les **intentions objectivées de groupe** à partir de leurs séquences d'états objectivés discrétisés.

Il nous est possible d'apprendre et de reconnaître, en temps réel, les comportements et intentions objectivés des groupes identifiés en utilisant notre innovation appelée **état relatif** et l'approche HMM. La partie suivante expérimentera notre approche.

L'état relatif, lorsqu'il est utilisé dans n'importe quel modèle existant, permet des résultats inédits de détection qui va de l'identification au couple apprentissage et reconnaissance. Les comportements objectivés réclament deux nouvelles observations d'un groupe pour se rendre compte d'un changement de comportement, mais sont d'une complexité fortement réduite.

Les limitations et avantages des modèles du domaine de l'intelligence artificielle, tel que dans la détection et la planification, ont été fortement révélées dans la littérature scientifique ces dernières années. Nous pensons que nous n'avons fait qu'ébaucher la surface que cet état relatif qui pourrait être utiliser dans d'autres types de méthodes se basant sur les états. Nous en obtiendrons des résultats inédits qui pourraient être combinés aux résultats des techniques utilisés couramment.

Conclusion

Nos modèles sont innovants, fonctionnels, sur différents niveaux d'observation, comblant beaucoup de limites actuelles et pouvant être optimisés. Il y a quelques points noirs à prendre en compte. Comme tout modèle de détection, il est soumis à l'incertitude des observations en entrée, mais le niveau **méso** permet d'avoir une observation moins incomplète et/ou moins imprécise (de plus haut niveau). Autrefois, la limite de la détection était le besoin d'information en qualité et en quantité à propos des agents / entités pistées dans la situation surveillée. Toutefois de nos jours, la généralisation des smartphones (et des téléphones portables) nous permet d'y pallier par la **chronolocalisation** (qui se fusionne parfaitement avec les systèmes de surveillance multi-capteurs déjà existants).

Notre procédé se basant sur **l'état relatif**, une donnée que nous avons créée, nous permet d'obtenir enfin une tenue / évaluation de la situation à un plus haut niveau de fusion de données. Nous en évaluons stochastiquement les objectifs et les intentions des groupes identifiés par le simple fait de surveiller leurs comportements collectifs relatifs aux entités de la situation. Sur ce genre de nouveaux résultats, des alertes simples peuvent être produites pour les forces de sécurité et les aider dans leurs décisions.

Il ne fait pas de doute que nos approches proposées seraient d'une grande utilité pour les forces de sécurité face à des situations asymétriques de type panique collective. Dans le domaine de la détection des comportements collectifs, que ce soit pour leur identification (et leur classification), leur apprentissage et leur reconnaissance, et leur anticipation ..., les idées évoluent et nous ont permis les innovations que nous vous avons présentées dans cette partie. Les comportements collectifs représentent un phénomène qui peut enfin s'expliquer et être géré afin d'en éradiquer ou du moins d'en limiter les effets néfastes.

Nous allons maintenant présenter comment nous les avons expérimentés dans la partie suivante.

Troisième partie

Expérimentations : Simulation Micro et Détection Macro vs Méso

"Le fossé séparant théorie et pratique est moins large en théorie qu'il ne l'est en pratique."

Auteur inconnu

Chapitre 6

Micro - Simulation d'une Foule en Panique

Sommaire

6.1 Implémentation logicielle	109
6.2 Expériences n° 1 : Mouvements de foule	111
6.3 Conclusion	113

Dans ce chapitre, nous présentons l'implémentation d'une application d'un système multi-agents. Les bénéfices de notre méthode sont indiqués par quelques résultats d'expériences. De cette manière, nous démontrerons qu'il est possible de simuler des comportements collectifs d'une foule en panique.

6.1 Implémentation logicielle

Dans le cas où nous chercherons à utiliser des données d'observations issues d'un véritable système de surveillance, nous ne saurions jamais à quel point **l'incertitude et l'imprécision** des observations en affecteraient les performances de détection. L'avantage d'utiliser notre propre implémentation nous permet d'obtenir des données **viables**. La plupart des études de la littérature scientifique ont perdu beaucoup de temps à apprendre des méthodes de fusion de données et à traiter les données. Nous contournons ce problème en les créant artificiellement par simulation. Toutefois, rien ne nous empêche de simuler la production de ces données comme issue d'un système de surveillance et non pas directement d'un log.

L'émergence de comportements collectifs s'observe dans une foule en panique, à cause des multiples mouvements de panique des groupes d'individus. Dans ce genre de système, l'environnement et les individus peuvent être complètement configurés. Puisqu'il est dangereux et coûteux de simuler réellement de tels scénarios, la possibilité de simuler différents scénarios d'une foule en panique est un avantage trivial.

L'illustration suivante du produit logiciel et sa légende permettront d'éclaircir nos expérimentations. Dans notre modèle décrit dans "[Micro - Modélisation des agents](#)" page 80, chaque individu est un agent. L'environnement, dans lequel les agents évoluent, est observé par une interface graphique. La programmation du système complet a été produite en langage informatique *Java*.




FIGURE 6.1 – Vue 2D d'une carte simulée

Nous présentons une illustration du comportement obtenu des agents. La Figure 6.1 utilise les représentations suivantes :

- Les **agents** ne se déplaçant pas sont représentés par un cercle **bleu**. Les agents en mouvement sont représentés par une flèche **bleue** indiquant la direction de leur déplacement actuel. Les agents décédés (à cause de la proximité d'une zone dangereuse ou par un piétinement) sont représentés par une flèche **magenta** ;
- Les **obstacles** (O) sont les murs **noirs** ;
- Les **dangers** (D) sont les zones **rouges** ;
- Les **abris** et **zones sécurisées** (S) sont les zones **grises** ;
- La **perception** (P) d'un agent est représentée par des zones **vertes**. La perception des agents est seulement bloquée par les obstacles et les zones de dangers. Afin de percevoir leur limite sur l'illustration 6.1, celles présentées ont été réduites comme lorsqu'il y a présence de fumée ;
- Les paramètres :
 - † La taille de la carte : 150×150 mètres ;
 - † Les agents ont une masse variant de 55 à 95 kg corrélée à un diamètre de 0.5 à 0.7 mètres, avec une perception d'environ 50 mètres variant selon l'environnement local.
 - † Les **récompenses** de l'algorithme 1 lorsqu'un agent se rapproche : $\{(abris, 4); (danger, -5); (saturation, -3); (cohésion, 0.5); (séparation, 1); (alignement, 1); (exploration, 5)\}$ (comme montré dans les figures 4.1 page 82). En changeant ces valeurs, l'intention de l'agent diminue ou augmente, dont la valeur nulle qui efface totalement l'intention. Avec cet exemple de

récompenses, les mouvements de la collectivité voisine ont toujours le meilleur effet sur le comportement de l'agent.

Dans cette situation, il y a quatre zones (une externe et trois abris internes) où les agents sont sécurisés. Certains agents sont décédés à cause des trois zones dangereuses (en feu par exemple). Cette situation peut représenter une grande salle avec trois mises à feu où les agents sont initialement disséminés dans l'environnement. Si nous avions produit des petits couloirs, il y aurait une **faible émergence** de comportements collectifs et la détection serait simple à prévoir comme la plupart des expérimentations de la littérature scientifique. Afin d'éviter de **biaisier la performance** des résultats par un nombre trop faible de chemins pouvant être empruntés, ces grands espaces permettent une grande variabilité de mouvements de groupes (et tester notre approche de détection sur un environnement complexe).

6.2 Expériences n° 1 : Mouvements de foule

L'observation des mouvements de la foule durant une itération de la simulation est une démonstration de la **validité** (quantitative et qualitative) de notre système multi-agents d'une foule en panique.

Initialement, parmi les 300 agents éparpillés dans l'environnement. Trois zones de dangers apparaissent que l'on peut apercevoir sur la séquence de vue de la Figure 6.2, tuant sur le coup les agents en contact. Quelques secondes plus tard, les agents dispersés se sont rassemblés en différents mouvements collectifs : nous avons une **émergence** de groupes par les comportements adoptés.

Beaucoup de groupes restent éloignés des murs et des zones de dangers, tandis qu'ils se bousculent au niveau des sorties et des abris. Durant le mouvement, nous notons que les agents (de chaque groupe) en fin du déplacement collectif ont une faible perception et ne connaissent sans doute pas la raison qui pousse les agents en tête du mouvement à avoir choisi ce chemin. Cela ressemble au comportement collectif dans lequel les individus suivent le mouvement de la foule en panique.

En suivant la séquence de vues 2D de la Figure 6.2, nous pouvons décrire que les groupes cherchent à se déplacer vers les abris tout en maintenant une distance minimale avec les dangers. De plus, quelques groupes quittent le lieu pour retrouver la zone sécurisée extérieure. L'ensemble des récompenses utilisé pour la modélisation de leurs intentions contraint les différents agents à préférer se précipiter dans les abris internes plutôt qu'externes. En désirant se rendre à l'extérieur en passant par une sortie étroite, les agents seraient ralentis ou stoppés dans leur mouvement. C'est ce que cherche à "éviter" notre fonction de récompense (i.e. l'algorithme 1 page 81 selon les paramètres des agents (i.e. section 6.1). Si nous retirons une partie de la récompense pour l'intention de l'agent de se rapprocher des abris, alors les agents préfèrent sortir à l'extérieur plutôt que rester à l'intérieur en présence des dangers.

L'illustration de la Figure 6.2 à $t = 25$ secondes montre qu'un groupe de quatre individus restent entre deux différentes zones dangereuses. Ce comportement peut être expliqué par le fait qu'ils n'ont aucune connaissance des positions des zones de sécurité, mais seulement celles des dangers et des agents morts qu'ils risquent d'approcher. N'apercevant pas les abris et les sorties par leurs faibles perceptions, ils restent sur place, ce qui ressemble à des personnes émotionnellement paniquées figées sur place. Ce comportement disparaît en augmentant la récompense de l'exploration dans les paramètres de l'agent (puisque la perception des phéromones déposées a alors plus d'impact chez la décision de la direction désirée par les agents, i.e. section 6.1).

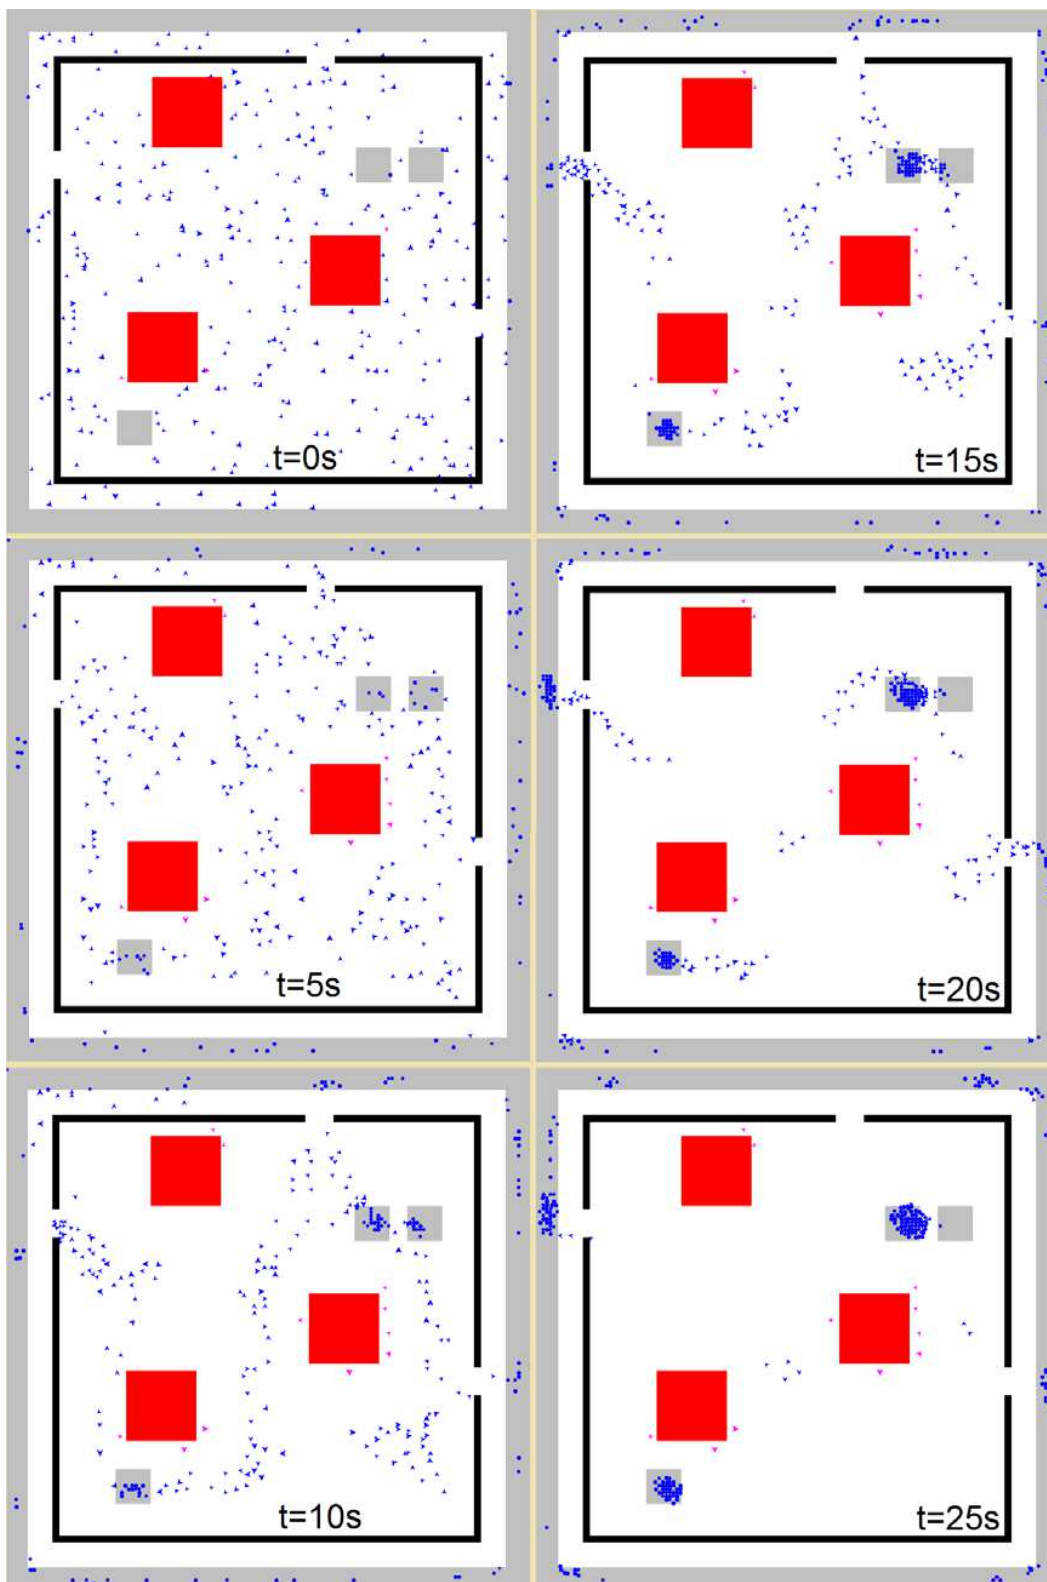


FIGURE 6.2 – Déroulement d'une itération avec 300 agents paniqués (à t = 0, 5, 10, 15, 20, 25 secondes)

6.3 Conclusion

L'expérimentation de notre système multi-agents dans notre environnement configurable a montré une certaine robustesse. L'aspect qualitatif de l'expérience vient d'être présenté. En effet, nous retrouvons chacune des intentions d'une foule en panique dans les décisions de ce système multi-agents, tout en permettant une émergence des comportements collectifs. Pour l'aspect quantitatif, si un comportement anormal pouvait être produit, nous l'aurions aperçu durant une des milliers d'itérations où cette expérience a été répétée afin d'apprendre les comportements (i.e. le sujet du chapitre suivant). Nous avons une validation quantitative et qualitative de notre modèle d'agent.

La limite principale de notre environnement simulé est qu'il ne présente qu'un aperçu en 2D. Toutefois, nous appliquerons un tel agent dans une situation asymétrique beaucoup plus complexe dans le dernier chapitre de cette partie. L'avantage principal est la possibilité de simuler une itération instantanément plutôt que de l'effectuer en temps réel. Une itération de l'expérience n° 1 se produit en moyenne en 30 secondes avec 300 agents. Une itération en mode "instantanée" va supprimer toute pause et seul ce qui tourne autour des agents va ralentir le processus (e.g. les décisions des agents, la mise à jour de la vue 2D, l'enregistrement des observations,...). Pour estimation, en faisant produire un millier d'itérations pour chaque variation du nombre d'agents (de 1 à 200) avec des positions initiales aléatoires, cela a pris 72h pour les simuler et logger le tout. L'apprentissage des comportements collectifs en se servant de ces logs est le sujet du chapitre suivant.

Chapitre 7

Macro - Identification, Apprentissage, et Anticipation des Mouvements de Panique

Sommaire

7.1	Expériences n° 2 : Apprentissage des mouvements récurrents	117
7.2	Expériences n° 3 : Localisation des risques liés à la panique collective	117
7.3	Expériences n° 4 : Anticipation des mouvements collectifs	119
7.4	Expériences n° 5 : Comportements face à des agents menaçants	120
7.5	Conclusion	121

Lors d'une situation d'urgence et d'évacuation, il est souvent impossible d'interpréter manuellement le comportement complexe d'une foule, ce qui est essentiellement dû au manque de personnels et de temps requis pour évaluer la situation. Une infrastructure statique peut comporter un réseau multi-capteurs pouvant ne pas fonctionner à ce moment-là ou ne pas être correctement déployé (notamment pour les zones critiques imprévisibles). Ce chapitre présente des expériences utilisant notre modèle macro afin de proposer de nouvelles solutions de détection appliquées du niveau **macro** au **micro**.

Notre modèle de détection a été formalisé au chapitre 4 page 79 et s'appuie sur les données produites lors de l'expérimentation n° 1 du chapitre 6. Les sections suivantes présentent nos commentaires à propos de quatre types d'expérimentations de notre fruit :


Exp. n° 2 : Apprendre les chemins récurrents empruntés par les groupes d'agents ;

Exp. n° 3 : Révéler les positions épidémiques où se produisent les interactions physiques lors des mouvements collectifs ;

Exp. n° 4 : Anticiper en temps réel les chemins qui vont être empruntés par les agents observés ;


Exp. n° 5 : Alerter les anomalies de comportements quand les agents n'agissent pas comme prévu.

Tout en démontrant l'utilité de notre approche de détection, chacune de ces expériences proposera de manière informelle une solution qui pourrait être employée face aux problèmes révélés par notre approche.



(a) Perception normale (500 itérations observées).

(b) Perception normale (1000 itérations observées).



(c) Perception limitée (1000 itérations observées).

FIGURE 7.1 – Les chemins récurrents et leurs directions empruntés par les agents lors d’une perception normale et limitée après l’apprentissage des comportements issus des multiples itérations de la simulation.

7.1 Expériences n° 2 : Apprentissage des mouvements récurrents

La Figure 7.1 nous montre les résultats d'un apprentissage de l'expérience n° 1 en utilisant les m observations de chacune des n itérations produites durant le chapitre précédent. L'illustration 7.1(a) présente les chemins empruntés de manière récurrente par cinquante agents (percevant normalement l'environnement) après 500 itérations d'apprentissage. Celle de 7.1(b) est le modèle après 1000 itérations d'apprentissage. Pour finir, l'image 7.1(c) est lorsque les agents avaient une perception réduite (comme lors de la présence de fumée).

Chaque ligne fine **rouge** correspond au déplacement ayant la plus grande probabilité de transition en partant de chaque état $q_{x,y}$ (pour rappel, 9 actions sont possibles : 8 directions et celle de rester sur place). Chaque flèche **bleue** correspond au déplacement le plus probable dans la zone où elle est affichée (*et produite à main levée*). L'apprentissage de 500 itérations de la simulation produit l'illustration 7.1(a) qui nous présente des mouvements collectifs affinés sur les chemins les plus courts de l'agent à son objectif (les zones sécurisées). En produisant 500 itérations supplémentaires 7.1(b), ces chemins sont devenus beaucoup plus corrélés à l'environnement.

Nous avons comparé les résultats d'apprentissage des comportements collectifs avec le modèle lors d'une perception normale des agents (Figure 7.1(b)) et celui lors d'une perception réduite (Figure 7.1(c)). Dans ce dernier cas, l'expérimentation en temps réel nous montre que les agents explorent lentement l'environnement, avec une grande variabilité et reste très proches de leur groupe. Cette expérience n° 2 montre que **plus** les agents ont une visibilité **réduite** de leur environnement, **moins** ils adoptent un comportement **dangereux** (par des déplacements lents en groupe et ainsi le nombre de bousculades disparaît). Au contraire, avec une visibilité **normale**, leur comportement **altruiste** est fortement **réduit** par leur comportement **égoïste** puisque leur objectif est leur propre sécurité en priorité (par des déplacements rapides).

Nous pouvons paramétrer un environnement virtuel basé sur un environnement réel. Nous pouvons placer des zones de dangers / obstacles et y obtenir des estimations sur le comportement de la foule lors d'une panique collective. Les sections suivantes présentent trois avantages de notre modèle de détection.

7.2 Expériences n° 3 : Localisation des risques liés à la panique collective

Nous avons combiné nos expériences n° 1 et n° 2 avec les **densités critiques de la foule** (i.e. les besoins en surface disponible par individu) décrites dans la section "[Apprentissage des interactions physiques](#)" page 84. Ce sont les conditions minimales de mobilité qui produisent les différents types de comportements lors des **catastrophes de foule** (*crowd disasters*). La variable $\psi_i(j)$ donne le nombre de fois où un agent est dans l'état i (de la position $\{x, y\}$) avec la densité critique j . La Figure 7.2 présente un exemple de localisation des densités critiques en temps réel lors d'une itération de l'expérience n° 1. Lors de chaque itération, à chaque instant t , pour chaque position i d'un agent, ψ_i est mis à jour pour la densité critique dans laquelle l'agent se trouve parmi a, b, c, d :

$a > 2.32 \text{ m}^2$: les piétons se déplacent en marchant avec une vitesse normale, pouvant éviter et contourner les passants ;

$a > 0.93 \text{ m}^2$: les possibilités de mouvements sont sensiblement restreintes et leurs vitesses sont notablement réduites (indiqués en **jaune** avec un "Y" dans la Figure 7.2).

$a > 0.46 m^2$: la mobilité de chaque piéton est réduite, ce qui est caractéristique des déplacements en groupe.

$b > 0.28 m^2$: des frôlements et des contacts involontaires se produisent (indiqués en orange avec un "O" dans la Figure 7.2).

$c > 0.19 m^2$: la foule se bouscule et des tensions psychologiques potentiellement dangereuses commencent à apparaître (indiqués en rouge avec un "R" dans la Figure 7.2).

$d > 0.14 m^2$: c'est la caractéristique commune des événements désastreux parmi la foule comme les suffocations et les piétinements.

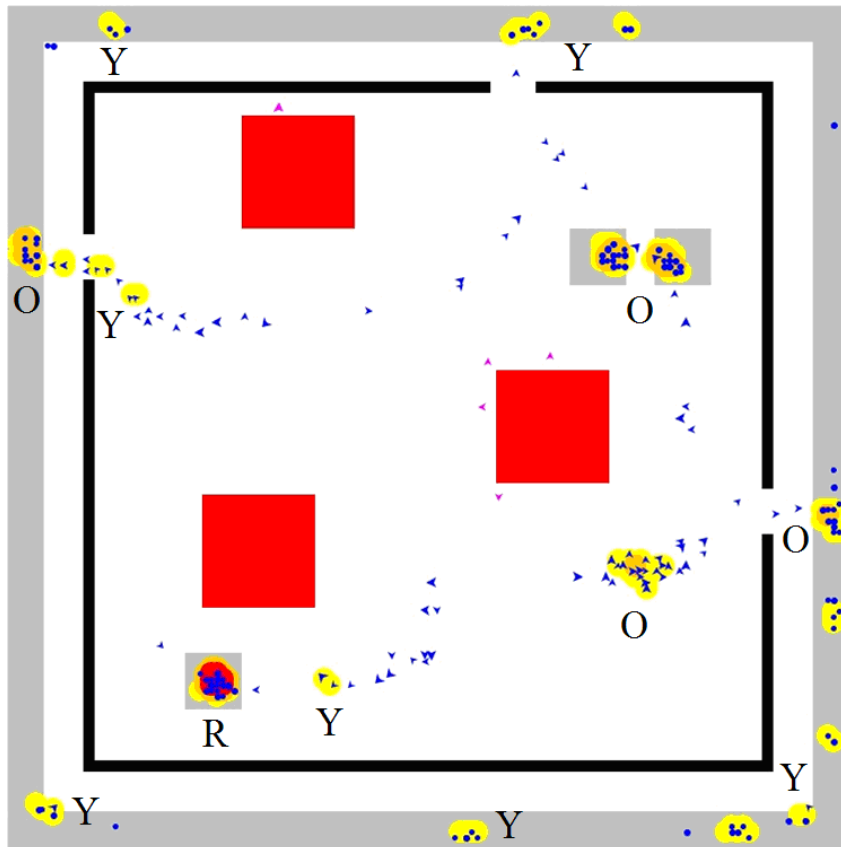


FIGURE 7.2 – Illustration des moments allant du simple frôlement physique aux bousculades et piétinements.

Une étude de Martin Burd²¹ [Shiwakoti et al., 2009] a démontré que des déplacements plus lents et une séparation de la foule par des obstacles contournables (non bloquant) sont une bonne solution pour éviter des bousculades et la panique générale qui en résulterait. Ces obstacles ont pour objectif de séparer la foule par elle-même et sont, par exemple, des banquettes transformant un couloir en deux corridors et des piliers devant les sorties. Dans notre simulation, en ajoutant de tels obstacles aux positions récurrentes de ces problèmes, nous avons pu vérifier à travers les nouveaux résultats que le nombre de bousculades, piétinements et suffocations est fortement diminué (comme dans l'étude de Burd). En prévention, nous pouvons modifier l'environnement pour réduire le risque d'interactions physiques dans le cas où la foule y entrerait en panique collective.

21. Source : www.futura-sciences.com/magazines/sciences/infos/actu/d/homme-cas-panique-suivez-fourmi-12545/

Pourcentage sur les 500 dernières itérations :		50 agents	100 agents	200 agents
Moyenne	HMM incluant les états basiques	88,09 %	82,12 %	76,78 %
	HMM incluant les sous-états	88,49 %	84,18 %	81,94 %
	Nombre moyen d'observations par agents	21,90	21,72	21,73
Écart type	HMM incluant les états basiques	3,12 %	2,88 %	1,79 %
	HMM incluant les sous-états	2,10 %	1,68 %	1,28 %
	Nombre moyen d'observations par agents	4,13	2,92	1,97

TABLEAU 7.1 – Qualité des prévisions des transitions d'états que les agents vont exécuter (après l'apprentissage de 1000 itérations).

En segmentant les états basiques en sous-états, cela augmente l'espace des états : $O(n \cdot m) = O(n \cdot 2^k)$ où :

- $n = l \times h$, n étant le nombre d'états possibles, l et h étant respectivement la largeur et la hauteur de la carte ;
- $m = 2^k$, m étant le nombre de sous-états possibles pour un état, k étant le nombre d'états voisins accessibles par n'importe quel déplacement d'un agent.

Les expériences ont été produites avec $l = h = 150$ mètres. S'il y a $k = 8$ états voisins pour chaque état (selon la manière de décomposer la carte) alors $|Q| = n \times 2^k = (150 \times 150) \times 2^8 = 5\,760\,000$. **Plus** le nombre de voisins augmente, **plus** la précision des anticipations augmente, **mais plus** le temps requis et la quantité d'observations requise pour l'apprentissage augmentent. Huit états voisins correspondent à un découpage avec une distance maximum d'un mètre à l'état de départ (pour les 1 + 8 directions). Si nous prenons une distance de deux mètres, alors ce nombre monte à 25 directions (= 1 + 8 + 16). Ce nouveau découpage inclut aussi toutes les configurations d'états occupés et non occupés parmi 25 sous-états pour chaque état. En résumé, si l'on augmente le nombre d'états voisins pour améliorer la qualité d'anticipation, le nombre d'états et de sous-états corrélés devient impossible à gérer en temps réel. Ceci est la limite de notre modèle.

7.4 Expériences n° 5 : Comportements face à des agents menaçants

La dernière question que nous adressons concerne la possibilité de comprendre pourquoi les agents fuient. Cette expérience additionnelle nous permet d'observer les comportements collectifs quand des dangers sont mobiles. Pour ce faire, des agents considérés comme **dangereux** par la foule sont produits.

La Figure 7.4 témoigne d'un nouveau comportement d'un groupe d'agents quand ceux-ci sont entourés par deux agents menaçants. Comme attendu, le groupe se dirige vers un abri et s'y arrête (i.e. de la case 0 à 1), tandis qu'un agent menaçant les poursuit. Quand cet agent menaçant entre dans l'abri (i.e. case 2), un agent **décède par les bousculades** de ses voisins lorsqu'ils s'échappent. Le groupe **se sépare** en deux pour éviter ce nouveau danger (i.e. case 3), le **contourner** (i.e. case 4), et se **rejoindre** à nouveau (i.e. case 5) pour **fuir** vers une autre zone sécurisée (i.e. case 6) à l'extérieur. Nous notons que le groupe évite l'autre abri interne pourtant plus proche, puisqu'il est déjà occupé par un second agent menaçant.

En se basant sur des probabilités de transitions d'un HMM macro, la probabilité que chaque agent du groupe utilise ce nouveau chemin qui s'éloigne d'un abri est **infinitésimale**. Le système le considère alors comme un **comportement anormal** et nous alerte, mais ne nous aide pas à détecter la raison (les

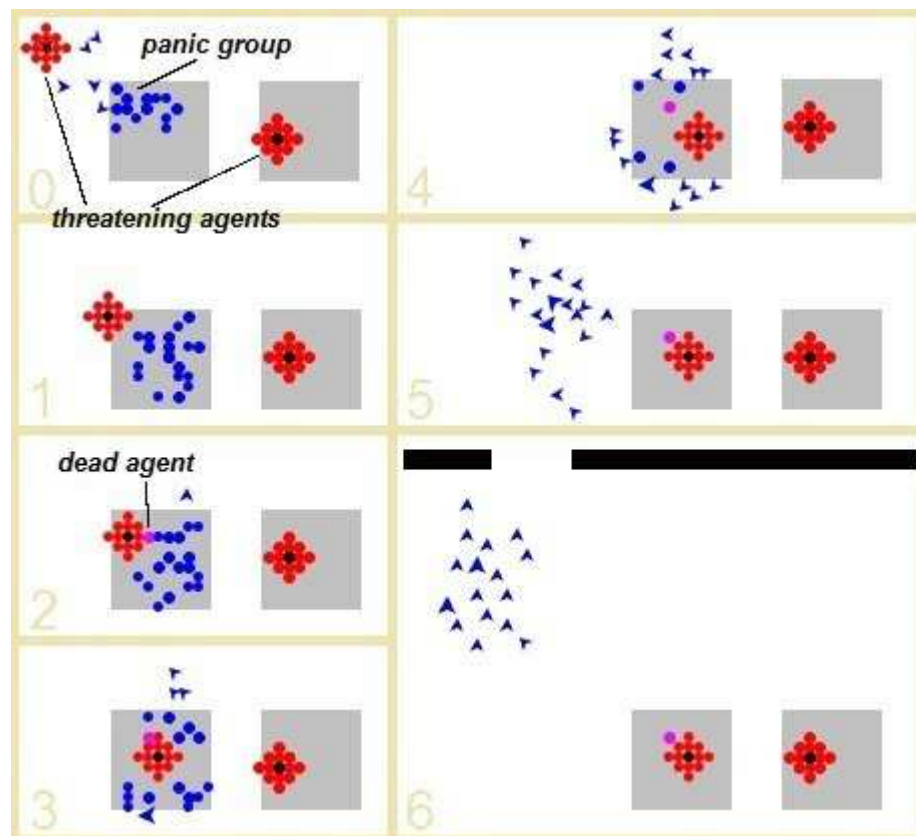


FIGURE 7.4 – Un comportement de groupe pris entre deux agents menaçants

individus menaçants). Dans le chapitre suivant, nous nous intéresserons à la détection automatique des raisons qui ont provoqué ces comportements collectifs, notamment en répondant à ces questions : quels sont les comportements des agents et quel est l'objectif qui produit leurs comportements collectifs ? de manière à ce que le système reconnaisse le comportement de fuite dont l'objectif est l'individu menaçant.

7.5 Conclusion

Par ses quelques expérimentations, notre **modèle macro** a fait ses preuves concernant ses fortes utilités pour les événements de foule en panique : apprendre les comportements collectifs récurrents, localiser les problèmes récurrents des mouvements collectifs, anticiper les mouvements de groupes et identifier les comportements anormaux. En perspective, nous pourrions apprendre un modèle macro pour chaque comportement collectif observable dans un environnement **asymétrique**. En effet, l'intégration et la fusion des meilleures techniques allant de la simulation à la détection nous permettraient un outil très **avantageux** et **innovant** pour les forces de sécurité.

Une **limite** est facilement répertoriée : la quantité requise de données d'observations pour l'apprentissage est si importante que seule une simulation peut les produire (malgré le fait que notre simulation le fait très rapidement).

Si nous revenons à notre désir d'utiliser un système multi-agents de détection, nous avons dans ce chapitre démontré qu'un **agent macro** pourrait surveiller la foule avec des modèles macro de comportements. Il apprendrait les comportements par les informations issues des **agents micro**, où chaque agent observe un individu. Lorsque la foule entre en panique, l'agent macro **notifie** les agents micro des individus paniqués d'anticiper leurs comportements et d'identifier une possible anormalité chez l'individu qu'il surveille. Comme la plupart des modèles de comportements, notre agent macro et micro ne comprendrait pas **la raison qui a provoqué** la panique collective ou les anormalités de comportements. Notre solution à ce propos est expérimentée dans le chapitre suivant où chaque **agent méso** observe un groupe qu'il a identifié et reconnaît ses comportements objectivés et ses intentions.

Chapitre 8

Méso - Détection de Comportements Objectivés de Groupe

Sommaire

8.1	Identification des groupes	124
8.1.1	Expériences n° 6 : Groupes en présence de multiples objectifs fixes	125
8.1.2	Expériences n° 7 : Multiples groupes en l'absence d'objectifs fixes	126
8.2	Apprentissage de HMM de comportements objectivés	131
8.2.1	Expériences n° 8 : En se basant seulement sur la position et la vitesse	131
8.3	Reconnaissance : HMM versus CEP	134
8.3.1	Expériences n° 9 : Détection dans un scénario complexe	135
8.3.2	Expériences n° 10 : Précision sur divers environnements asymétriques	136
8.4	Détection de menaces dans un environnement complexe dynamique	141
8.4.1	Expériences n° 11 : Identification d'un agent menaçant parmi une foule	142
8.5	Conclusion	144

La détection par des **agents méso** est le point culminant de notre **innovation**. Les expériences suivantes présentent quelques résultats de notre processus d'identification des groupes, d'apprentissage des comportements objectivés, de leur reconnaissance en temps réel, de l'identification des intentions (telles que des menaces) en situation asymétrique. Dans l'optique d'exposer l'utilité de notre approche, nous terminons ce chapitre par une expérience où nous désirons **détecter un kamikaze** (i.e. un homme portant une bombe cachée sur son torse) se dirigeant vers sa cible (i.e. un journaliste) parmi une foule simulée en 3D. Bien sûr, certains groupes ont des comportements collectifs anormaux à son contact.

Durant les expérimentations de ce chapitre, notre approche utilisant les états relatifs discrétisés dans un HMM a été comparée au CEP (i.e. section 2.2.3 page 49). Notre implémentation en langage **Java** communique maintenant avec un **serious game** (jeu sérieux) du nom de *Virtual Battle Space 2* (VBS2)²². C'est une simulation 3D d'un environnement hautement réaliste. L'objectif de sa conception est d'aider à l'entraînement de personnes telles que les forces de sécurité. Pour gérer les HMMs, nous utilisons la librairie *jahmm*²³ disponible en ligne. Cette librairie a été choisie puisqu'elle permet de créer nos

22. Bohemia Interactive Simulations, Australia, 2011, <http://vbs2.com>

23. J.M. Francois, Jahmm (*Java Hidden Markov Model*), 2006, <http://code.google.com/p/jahmm/>

propres états cachés et observables, et qu'elles disposent des algorithmes standards qui s'appliquent au HMM. Pour gérer les CEP, nous utilisons *Drools*²⁴ un moteur de règles (*rule engine*) et un logiciel libre distribué selon les termes de la *licence Apache* (et codé en *Java*).




FIGURE 8.1 – Légende des vues 2D

Les illustrations 2D de notre implémentation (en langage *java*), qui sont présentées dans ce chapitre, incluent toujours cette même **légende** :

- ◇ La carte 2D est découpée par des lignes **grises** de 10 mètres × 10 mètres pour indiquer la taille de l'environnement.
- ◇ Chaque objectif est représenté par un losange **bleu** (quand il est fixe).
- ◇ Chaque groupe est représenté par un ensemble d'agents partageant une couleur commune unique au groupe.
- ◇ Chaque agent est dessiné par une flèche indiquant sa direction et est relié à la position de l'état fusionné du groupe par une ligne **rouge** ;
- ◇ Chaque déplacement d'agent est illustré par une ligne **grise** en pointillé et une ligne **noire** en pointillé pour le déplacement du groupe (par sa séquence d'états fusionnés).

8.1 Identification des groupes

Les deux sous-sections suivantes présentent deux types de résultats de notre identification des groupes. L'expérience n° 6 correspond à des situations asymétriques ayant la présence de peu de groupes, mais en présence de multiples objectifs fixes, donc qui produisent beaucoup de comportements objectivés individuels. L'expérience n° 7 correspond à une situation plus complexe par un grand nombre d'agents et de groupes, mais qui ne disposent pas d'objectifs fixes. Ce dernier cas est pour démontrer que nous pouvons l'appliquer sur une foule et que la présence de groupes mobiles en tant qu'objectifs ne diminue pas la qualité d'identification des groupes, ou peut-être celle de l'assignement des agents aux groupes.




FIGURE 8.2 – Identification de groupes par notre algorithme en présence de divers objectifs fixes

8.1.1 Expériences n° 6 : Groupes en présence de multiples objectifs fixes

La Figure 8.2 contient quatre vues 2D issues de trois scénarios différents (i.e. légende page 124). Les sous-figures 8.2(a) et 8.2(b) exposent deux moments consécutifs (à $t_1=21s$ et $t_2=53s$) où deux groupes se déplacent parmi cinq objectifs. Pendant ce scénario, quand le groupe s'arrête quelques secondes sur la position d'un objectif fixe, notre algorithme finit par considérer qu'ils ont le même comportement relatif et les assigne au groupe. Toutefois, deux observations d'une remise en mouvement suffisent à ce que l'algorithme réidentifie correctement les membres du groupe (sans l'objectif).

24. Drools est fédéré dans la multi-plateforme *Jboss*, 2011, <http://www.jboss.org/drools>

Celle de 8.2(c) illustre deux groupes qui sont partis de l'*Est*, se sont séparés pour contourner / éviter un objectif (i.e. un obstacle) chacun de son côté et se sont ensuite recroisés. À cet instant, la plupart des algorithmes de l'état de l'art auraient fusionné les deux groupes en un seul puisqu'ils se sont rejoints et suivent la même direction. Notre algorithme prend en compte l'historique des comportements relatifs des agents des deux groupes et n'a pas fait cette erreur commune.

Le dernier 8.2(d) présente un groupe qui a entouré un à un quatre des cinq objectifs fixes, mais un 5^{ème} objectif mobile s'est mis à suivre le groupe. Dans cette dernière vue, nous observons que l'objectif qui suivait le groupe de très près (pendant les 60 derniers mètres parcourus à vitesse de course) n'a pas été identifié comme étant un membre du groupe. En effet, son comportement relatif était différent de celui du groupe.

Parmi les scénarios **simples** que nous avons simulés, l'identification des quelques groupes parmi autant d'objectifs fixes et l'assignement des agents aux groupes nous donne une précision supérieure à **98%**. Son premier avantage est de considérer l'historique des comportements relatifs des agents pour identifier les groupes. Ceci évite les fausses détections des approches de l'état de l'art, mais cela augmente le nombre de calculs par rapport à l'historique des états gardés en mémoire. Toutefois, nous désirons tester cet algorithme sur une **foule** pour en observer les limites.

8.1.2 Expériences n° 7 : Multiples groupes en l'absence d'objectifs fixes

Les captures d'écrans (*screenshots*) de VBS2 dans la Figure 8.3 nous montrent un scénario simple pour tester notre algorithme 2 page 96 de détection de groupe. Ce scénario simule initialement treize groupes parmi une centaine d'agents (civils et soldats). Pendant le scénario, chaque groupe choisit la position initiale d'un des autres groupes et s'y déplace. Ainsi à chaque itération, cela provoque aléatoirement des rassemblements et des scissions de groupes. Les captures d'écrans 8.3(a) et 8.3(b) montrent une vue 2D du scénario à un instant initial et avancé, et une vue 3D pour 8.3(c) et 8.3(d). VBS2 signale la position actuelle des groupes par un rectangle avec une croix. Les lignes vertes et bleues indiquent l'observation des mouvements de groupe. Malgré ce grand espace vert sans obstacle, une vue 2D et 3D de la situation, il est difficile pour n'importe qui d'identifier les groupes et de suivre leurs mouvements.


Notre implémentation en langage *Java* lit en temps réel les observations enregistrées (i.e. un *log*) par notre plugin connecté à VBS2. Dans la réalité, ce log pourrait être produit par un système de surveillance tel qu'un réseau de caméras et/ou d'un drone. La Figure 8.4 nous montre une observation 2D de ce que notre système détecte (i.e. légende page 124).

Le nombre d'agents et d'observations pour chaque agent étant important, nous avons cherché et utilisé quelques optimisations de l'algorithme 2 proposées page 94 afin de pouvoir l'appliquer en temps réel.


Pour ce scénario, nous obtenons 88% de précision pour l'assignement de chaque agent à son groupe réel, et 100% des groupes détectés existent réellement. Vous pouvez voir trois exemples de résultats dans les Figures 8.5 pages 129 et 130. Les sous-figures droites 8.6(b), 8.6(d) et 8.7(f) sont respectivement les résultats d'identification des groupes qui sont révélés par VBS2 dans les sous-figures gauches 8.6(a), 8.6(c) et 8.7(e). Quand un agent est assigné au mauvais groupe par notre algorithme, il est entouré par un rond **rouge**.




(a) Vue 2D de VBS2 à $t=10s$



(b) Vue 2D de VBS2 à $t=50s$

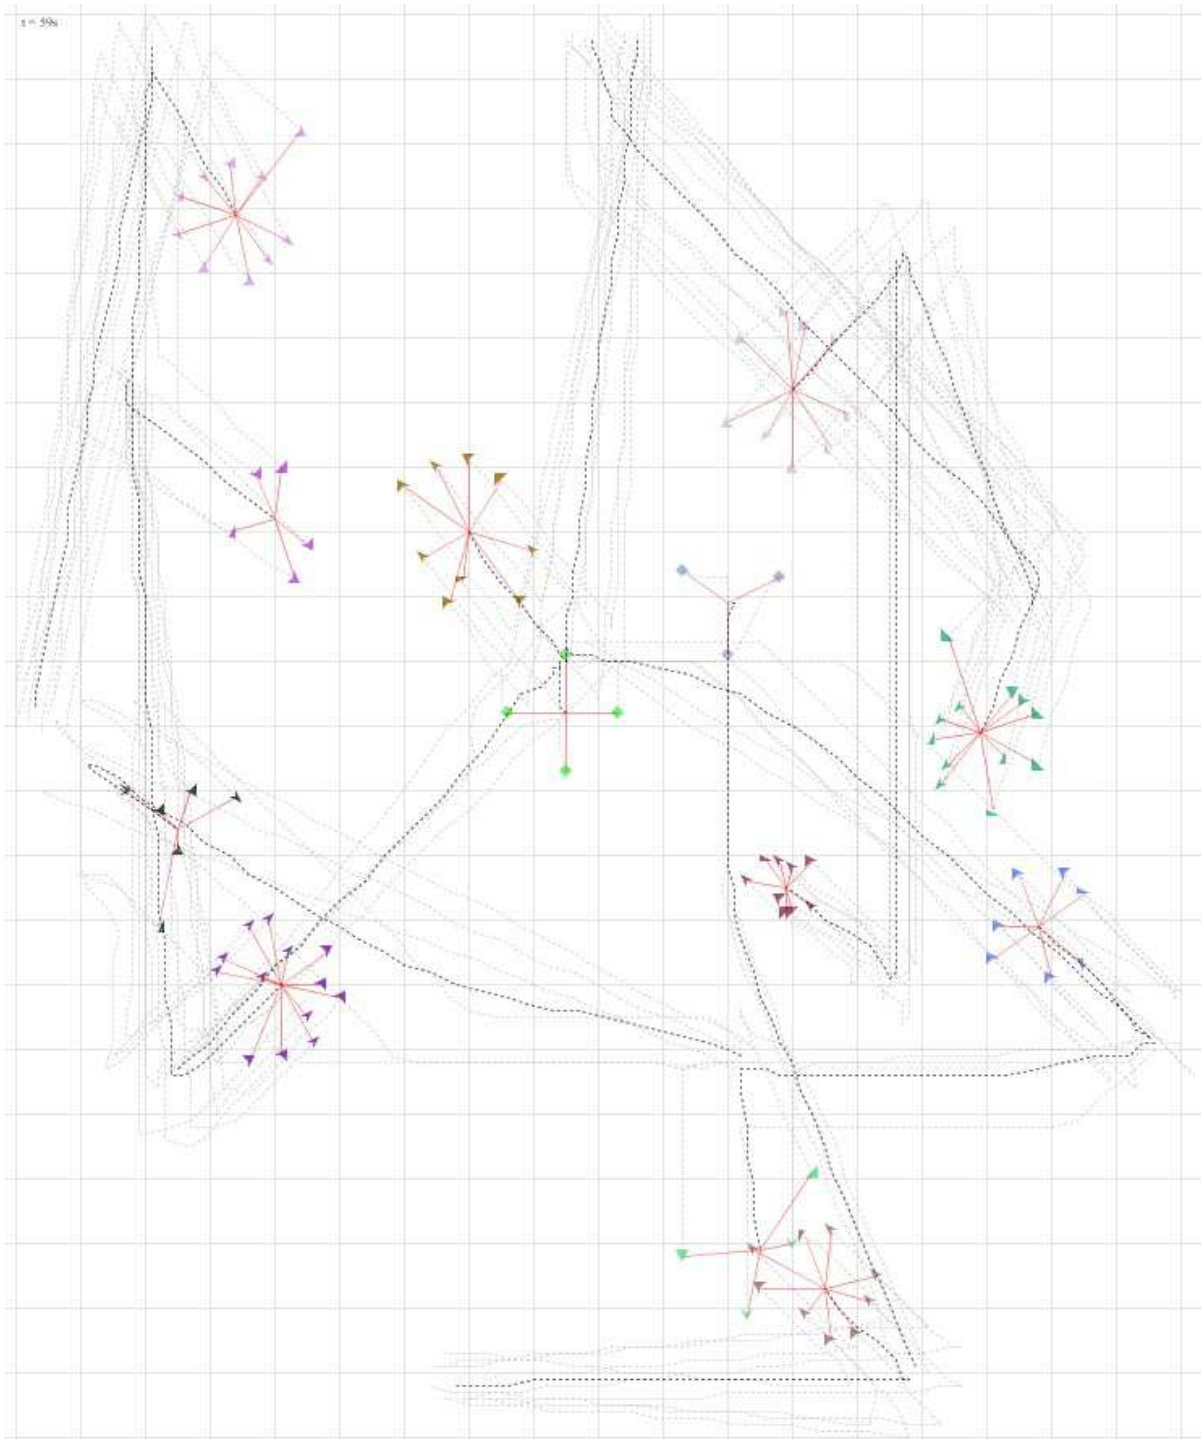


(c) Vue 3D de VBS2 à $t=10s$



(d) Vue 3D de VBS2 à $t=50s$


FIGURE 8.3 – Vue de VBS2 en 2D/3D de 13 groupes parmi 100 agents en mouvement




(a) À $t=59s$, 13 groupes sont identifiés par une couleur distincte et les agents sont indiqués par une flèche de leur direction actuelle ; Les membres sont reliés par une ligne rouge à l'état fusionné du groupe ; Les pointillés gris des déplacements des membres montrent qu'ils suivent correctement les pointillés noirs de leur séquence d'états fusionnés.

FIGURE 8.4 – Vue 2D de notre implémentation des 13 groupes parmi 100 agents en mouvement


FIGURE 8.5 – Identification par notre approche des 13 groupes parmi 100 agents en mouvement




(a) Vue partielle de quelques groupes indiqués par le serious game à $t=15s$



(b) Parmi les groupes détectés par notre algorithme, seulement deux agents (encerclés en rouge) ne sont pas correctement assignés




(c) Vue partielle de quelques groupes indiqués par le serious game à $t=30s$




(d) Seulement trois agents ne sont pas correctement assignés puisqu'ils ont un comportement relatif différent

FIGURE 8.6 – Identification par notre approche des 13 groupes parmi 100 agents en mouvement



(e) Vue partielle de quelques groupes indiqués par le serious game à $t=45s$



(f) Quelques groupes sont en train de se croiser et seulement quatre membres sur cent agents ne sont pas correctement assignés (encadrés en rouge)



(g) Vue administrateur partielle de VBS2. Cet exemple de scénario asymétrique présente un groupe (détectable par notre approche) de soldats en train d'appréhender une entité (i.e. un objectif) ayant un comportement suspicieux.

Parmi les mouvements des 100 agents assignés dans 13 différents groupes, seulement quelques erreurs sont attendues quand les agents n'ont pas le même comportement relatif que celui de leur groupe. Par exemple, quand un agent est à une certaine distance de son groupe alors que les autres membres sont compactés, ce qui se produit quand cet agent quitte le groupe. Notre algorithme a besoin au minimum de deux nouvelles observations afin d'assigner un agent à son nouveau groupe.

La plus importante partie de notre contribution est que l'identification des groupes est seulement basée sur la position et la vitesse des agents. Notre méthode a démontré que les séquences observées des positions relatives et vitesses relatives des agents sont suffisantes pour détecter les groupes avec précision. De nos jours, tout système de surveillance fournit ces deux types de variables. Par comparaison, les techniques de l'état de l'art requièrent plus de variables ou offrent une plus basse précision. Le challenge est maintenant d'exécuter cette détection de groupe dans une foule ayant un grand nombre d'entités. De même qu'il serait intéressant de savoir si le fait de rajouter des variables supplémentaires (telle que l'orientation relative) augmenterait la précision d'assignement.

Un avantage additionnel est la possibilité de détecter les différents types de groupes parmi la foule. Si nous ajoutons certaines informations minimales à propos des entités, alors il serait possible de détecter les sous-groupes où les membres sont éparpillés parmi les groupes (i.e. cachés) mais ont le même comportement relatif (e.g. violent). Par exemple, ces individus ramassent des projectiles (e.g. pierres) sur le sol et les lancent sur une cible commune (e.g. les forces de sécurité). Leur corps change séquentiellement de position : à genoux, debout, un bras levé. Durant un lancement de projectiles, la séquence observée de la position du corps peut être ajoutée aux états et permettre de détecter les groupes ayant un comportement collectif violent relatif à un objectif.

En conclusion, le modèle proposé formalise un état de groupe et **caractérise** un comportement de groupe **indépendamment** de sa taille. Cette technique **n'a pas besoin** d'apprentissage, c'est pourquoi c'est une technique d'**identification** et non de reconnaissance. Nous l'utilisons dans le cadre de notre reconnaissance des comportements objectivés de groupe dans les sections suivantes.

8.2 Apprentissage de HMM de comportements objectivés

Dans l'expérience n° 8, nous présentons comment nous avons procédé à l'apprentissage de comportements objectivés de groupe, un par HMM. Comme ensemble d'états nous reprenons les états relatifs discrétisés présentés en section 5.1.2 page 92. Quelques résultats sont notamment illustrés afin de présenter la capacité de notre modèle à apprendre différents comportements objectivés. Toutefois, comme toute phase d'apprentissage d'un modèle, sa performance repose sur la qualité et la quantité des données d'observations des comportements à apprendre.

8.2.1 Expériences n° 8 : En se basant seulement sur la position et la vitesse

Dans notre cas d'utilisation, d'un groupe envers un objectif, la probabilité de quatre comportements objectivés distincts doit être déterminée en temps réel. Ces comportements sont :

- $\lambda^{c \rightarrow g}$ le groupe se dirige vers l'objectif,
- $\lambda^{c \leftarrow g}$ le groupe s'éloigne de l'objectif,
- $\lambda^{c \circ g}$ le groupe contourne / évite l'objectif, et

$\lambda^{c \leftrightarrow g}$ le groupe n'a pas de mouvement relatif envers à l'objectif (prenant en compte l'absence de mouvement et celui totalement corrélé).

Afin de modéliser un HMM sur un **comportement objectif de groupe**, l'apprentissage des données d'observations (issues de scénarios variés) est produit en utilisant l'algorithme *Baum-Welch* [Rabiner and Juang, 1986]. Cet algorithme nous maximise les probabilités de chaque séquence d'observations à apprendre en mettant à jour les paramètres A , B et Π (i.e. section 3.2.1 page 55).

Pour chaque comportement objectif de groupe que nous voulons apprendre, nous avons simulé une vingtaine de différents scénarios simples où un seul groupe produit uniquement ce comportement en fonction d'un seul objectif. Par ce fait, nous avons réduit notre besoin de supervision pour classer les séquences d'observations. Lors d'un scénario, la séquence d'observation du comportement est continue. Nous la découpons automatiquement à différents intervalles réguliers afin de multiplier le nombre de séquences à apprendre et d'en améliorer la précision du modèle.

Parmi les scénarios simulés, les groupes sont composés de 4 à 16 civils ou soldats (qui, dans ce cas, sont en équipe et se déplacent en formation militaire). Il y a certains objectifs qui peuvent être mobiles ou fixes et sont définis par les autres entités de la situation (i.e. autres groupes, agents seuls, importantes positions,...). Quand l'environnement possède quelques obstacles, le groupe peut être amené à les éviter. Les observations de chaque position et vitesse des agents sont obtenues chaque seconde afin de calculer leurs séquences d'états relatifs discrétisés (i.e. le processus décrit dans la section 5.1.2 page 92).

Six résultats d'apprentissages sont illustrés dans la Figure 8.7. La légende de ses sous-figures est la suivante :

- ◇ Chaque sous-figure présente le même ensemble Q^{DR} des 16 **états relatifs discrétisés** (basé sur la position relative et la vitesse relative, i.e. section 5.1.2) ;
- ◇ Chaque arc fléché représente une **probabilité de transition** a_{ij} d'un état i vers un autre j . Par défaut, chaque probabilité est non nulle telle que $a_{ij} = 1/|Q^{DR}|, \forall i, j \in Q^{DR}$ (soit $1/16 = 6.25\%$). Afin d'éclaircir le grand nombre de transitions ($|Q^{DR}|^2$) qui serait à afficher, nos illustrations les affichent seulement quand la probabilité est supérieure à ce minima (i.e. $a_{ij} > 0.0625, \forall q_i, q_j \in Q^{DR}$). Pour comprendre l'importance d'une transition et les comparer facilement, la **largeur** de chaque flèche est directement **proportionnelle** à sa probabilité de transition. La figure 8.7(f) est un HMM par défaut (sans apprentissage effectué), nous pouvons y remarquer l'absence de transition ;
- ◇ Chaque double cercle en pointillé nous indique la probabilité qu'un comportement commence dans un **état initial** qui lui est connecté (basé sur $\pi_i > 0, \forall q_i, q_j \in Q^{DR}$) ;
- ◇ Un comportement est ainsi décrit par ses séquences d'états DR en commençant dans un état initial, en suivant les transitions jusqu'à un état final.

Avec ce type de représentation, nous remarquons facilement que les comportements objectifs de groupe des sous-figures 8.7(a) et 8.7(b) sont inversés. En effet, leurs états DR initiaux et finaux sont opposés : par exemple, $\langle p_n, v_n \rangle$ est un état DR final du comportement de rapprochement (8.7(a)) et est un état DR initial du comportement d'éloignement (8.7(b)).

Pour chaque comportement, seulement un sous-ensemble d'états DR a été rencontré durant l'apprentissage et les probabilités de transitions sont différentes si deux comportements se chevauchent. Par exemple, nous avons deux comportements objectifs composés de deux plus simples, ils se chevauchent :

1. **parallèlement** pour 8.7(e) quand "le groupe suit un objectif" : "le groupe se dirige vers l'objectif" (8.7(a)) et reste à distance constante ;
2. **séquentiellement** pour 8.7(g) quand "le groupe se dirige vers un objectif et l'encercle" : "le groupe se dirige vers l'objectif" (8.7(a)) puis "il n'a plus de mouvement relatif" (8.7(d)).

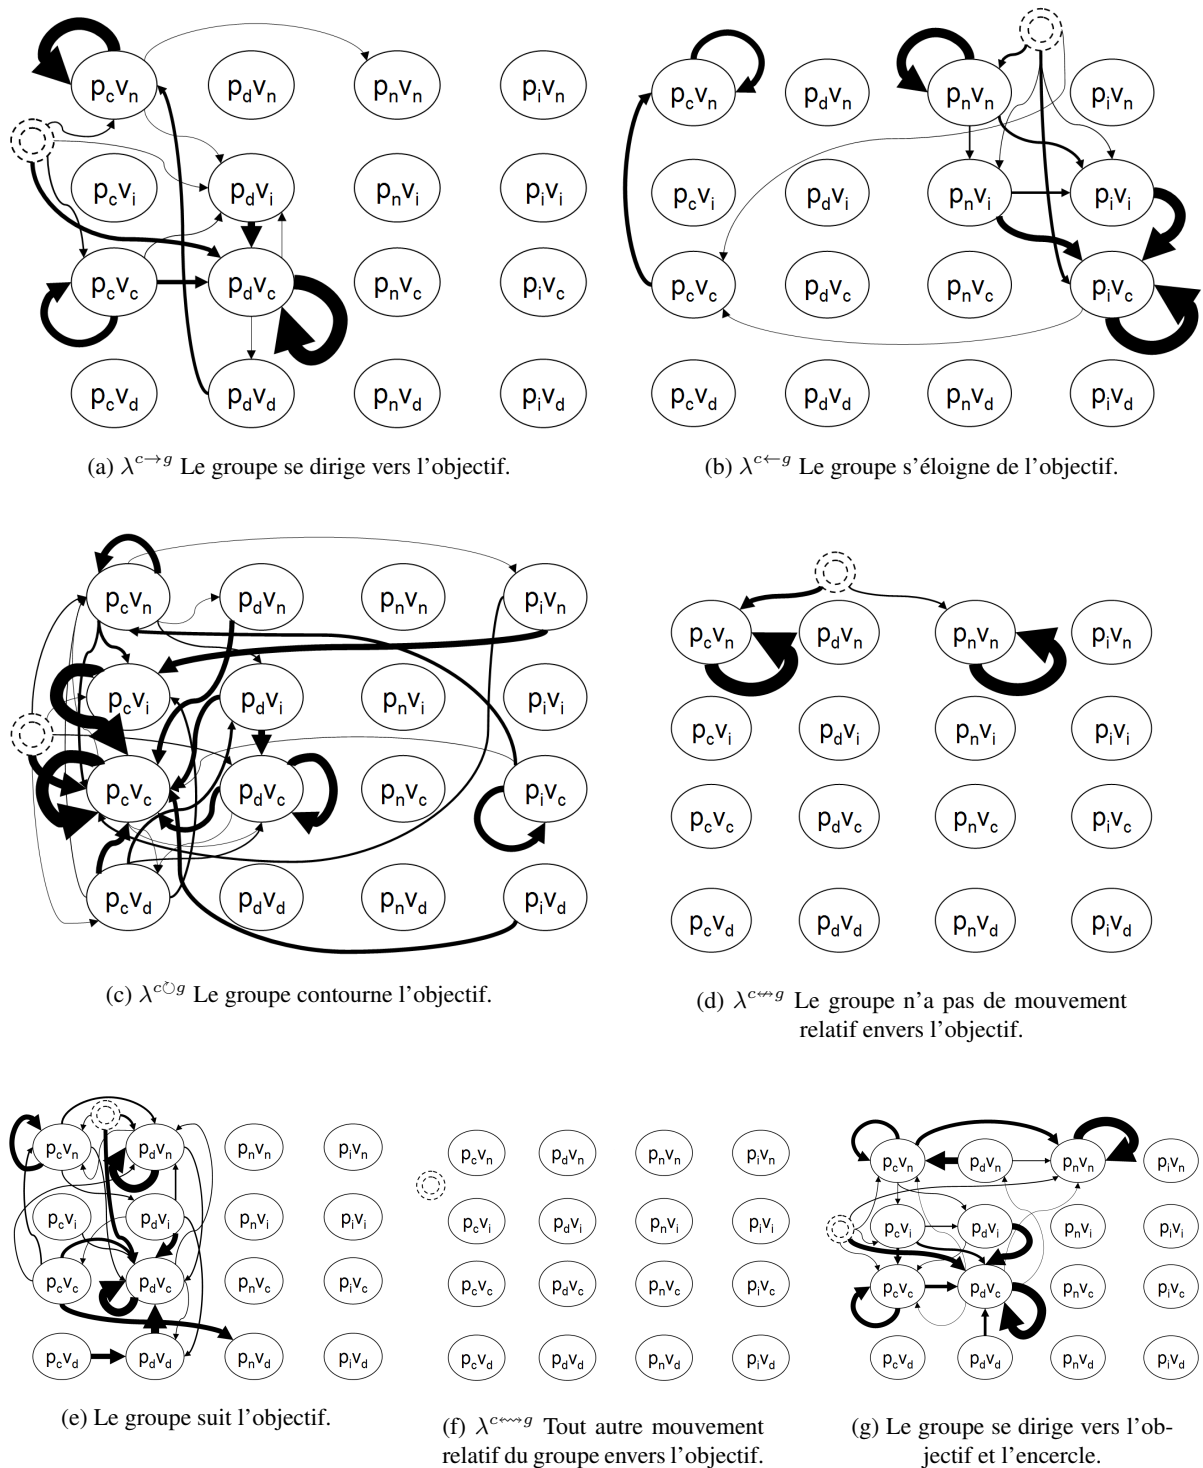


FIGURE 8.7 – Exemples de HMMs appris de comportements objectivés de groupe (où sont affichées proportionnellement les probabilités de transitions $a_{ij} > 1/|Q| = 6.25\%$ parmi l'ensemble des états relatifs discrétisés).

Comme l'illustrent ces sous-figures, les transitions sont toujours plus complexes quand un comportement en chevauche d'autres. Notre modèle surmonte cette difficulté en démontrant la possibilité d'apprendre une variété de **comportements complexes**, pouvant être définis sur des comportements simples se produisant **séquentiellement** et / ou **parallèlement**. Toutefois, **nous n'utiliserons que les quatre premiers (8.7(a), 8.7(b), 8.7(c), 8.7(d)) afin d'éviter de fausses détections** lorsque des comportements se chevauchent (i.e. en transition d'un ancien vers un autre et/ou puisqu'ils ne sont pas au même niveau d'observation) et **celui du HMM sans apprentissage (8.7(f))**. Ce dernier est important, puisque si sa probabilité est plus importante pendant une reconnaissance, c'est que le comportement observé n'a pas été correctement appris. Nous procéderons alors à son ajout dans les séquences à apprendre du modèle déjà appris ou en créant un modèle si le modèle n'est pas défini (ce qui ne s'est jamais produit).

Pour tous ces modèles HMM de comportements objectivés, l'apprentissage des quelques centaines de séquences d'observations n'a mis qu'une **dizaine de secondes** à être traité par l'algorithme. Cette rapidité nous prouve deux choses :

- (1) Notre modèle **méso** est d'une **faible complexité**, malgré le fait qu'il **caractérise** un comportement d'un groupe (d'une taille variable) envers un objectif (de n'importe quel type d'entité) et s'applique quel que soit l'environnement et la situation (et pas seulement ceux asymétriques) ;
- (2) Si un comportement n'est pas reconnu (parmi les modèles appris) pendant la phase de reconnaissance, alors celui-ci pourra être identifié par un superviseur (humain) et appris automatiquement. La probabilité que le système ne le reconnaisse pas la fois suivante en sera fortement réduite. Nous avons donc **un modèle capable d'apprentissage par renforcement semi-supervisé**.

Comme tout nouveau modèle appris, il nous faut maintenant tester ses performances de reconnaissance en comparaison d'une autre approche existante.

8.3 Reconnaissance : HMM versus CEP

Afin de comparer les résultats de notre approche proposée (i.e. sur les états relatifs discrétisés) dans les *Hidden Markov Model*, les *Complex Event Processing* (i.e. section 2.2.3 page 49) ont été utilisés comme méthode alternative. En effet, cette approche est souvent utilisée (i.e. notre participation au **projet européen DEM@CARE** en Annexe 10 page 181) pour la détection d'événements complexes [Bowman, 2004, Luckham, 2001]. L'expérience n° 9 de détection est produite sur un ensemble de scénarios où les mouvements collectifs sont simulés par un système multi-agents dans les *serious game VBS2*.

Drools²⁵ a été utilisé afin d'écrire des règles de CEP. Nous nous sommes servis de l'état de l'art pour reproduire certaines fonctions qui sont les plus comparables aux diverses étapes de notre approche. Nous en présentons le processus suivant :

1. Les règles prennent en entrée les observations des agents en tant que des faits bas niveaux.
2. En comparaison de notre approche (notamment les sections 5.1.2 page 92 et 5.3 page 99), ces règles reproduisent certaines fonctions que nous avons retenues de l'état de l'art.
3. De notre algorithme 2 page 96, l'identification du groupe s'obtient en analysant les probabilités d'interactions et de la proxémie (section 2.2.1 page 41, notamment [Chang et al., 2011]).

25. Drools est fédéré dans la multi-plateforme *Jboss*, 2011, <http://www.jboss.org/drools>

4. En comparaison de notre état fusionné (section 5.1.1 page 91), les groupes sont représentés par un état centroïde (section C. page 47) ;
5. En comparaison de notre assignement des comportements objectivés aux groupes (section 5.3 page 99), les comportements et les objectifs se décrivent par des règles se basant sur l'évolution et la combinaison des valeurs des variables du groupe :
 - la vitesse : le mouvement quand elle est non nulle, la poursuite ou la fuite quand elle est grande, sinon il n'y a pas de mouvement ;
 - la distance : se traduit par "en éloignement, en rapprochement ou constante" quand celle-ci diminue, augmente ou est constante par rapport à l'objectif ;
 - l'orientation : du mouvement indique l'intention de se diriger (avec une différence inférieure à 45°), de s'éloigner (avec une différence supérieure à 135°) ou de contourner (entre [45° ; 135°]) l'objectif.
6. Les règles ont ainsi produit des faits de haut niveau à propos des comportements collectifs et des objectifs de groupes.

8.3.1 Expériences n° 9 : Détection dans un scénario complexe

Avec les **quatre comportements objectivés** $\langle \lambda^{c \rightarrow g}, \lambda^{c \odot g}, \lambda^{c \leftarrow g}, \lambda^{c \leftrightarrow g} \rangle$, nous avons ajouté un **comportement inconsistant** $\lambda^{c \rightsquigarrow g}$ qui est un HMM par défaut sans apprentissage. Si $\lambda^{c \rightsquigarrow g}$ a une plus haute probabilité de reconnaissance alors les séquences d'observations utilisées (durant l'apprentissage du comportement correspondant à celui observé) doivent être corrigées (telles que des suppressions des séquences qui peuvent produire un biais dans l'apprentissage lorsque des comportements se chevauchent, et/ou l'ajout de séquences proches de celle qui n'a pas été reconnue).

La figure 8.8 nous présente un résultat, en temps réel, de détection des comportements objectivés de groupe dans un scénario complexe. Pour explication :

- Sous chaque objectif, des probabilités sont affichées sur deux colonnes de cinq lignes. Les lignes (1) à (5) sont, dans l'ordre, les cinq comportements objectivés $\langle \lambda^{c \rightarrow g}, \lambda^{c \odot g}, \lambda^{c \leftarrow g}, \lambda^{c \leftrightarrow g}, \lambda^{c \rightsquigarrow g} \rangle$. La colonne de gauche est pour le groupe C^1 et de droite pour le groupe C^2 .

- Chaque probabilité représente l'estimation d'un comportement objectivé qu'un groupe est en train d'exécuter en fonction de cet objectif.

- Comme exemple simple, C^1 est en train de se rapprocher de *Donkey* à 95.88%, de s'éloigner de *Cow* à 99.73%, d'éviter *CIVL* à 74.34% (de même qu'il passe à côté de *Goat* et *Dog*).

- Comme exemple complexe, C^2 se dirigeait d'abord vers *CIVL* mais se dirige maintenant vers *Goat* (esquivant *CIVL*). Nous apercevons qu'avec les 43.87% et 56.13% de *CIVL* pour C^2 , la reconnaissance continue à prendre en compte les anciennes observations du premier comportement (ce qui est utile si le nouveau est temporaire). Les probabilités indiquent maintenant que C^2 évite *CIVL* et se dirige vers *Goat* à 95.88% (et l'évitement est descendu à 4.12%).

Comme nous venons de le voir, quand **des comportements se chevauchent**, ils sont aussi **détectés** par une probabilité toujours supérieure à 1%. Toutefois, comme seul celui à la plus grande probabilité sera considéré dans le calcul de la précision de notre approche, les deux observations durant un changement de comportement risquent de la diminuer sensiblement. L'expérience n° 10 suivante étudie cette situation.


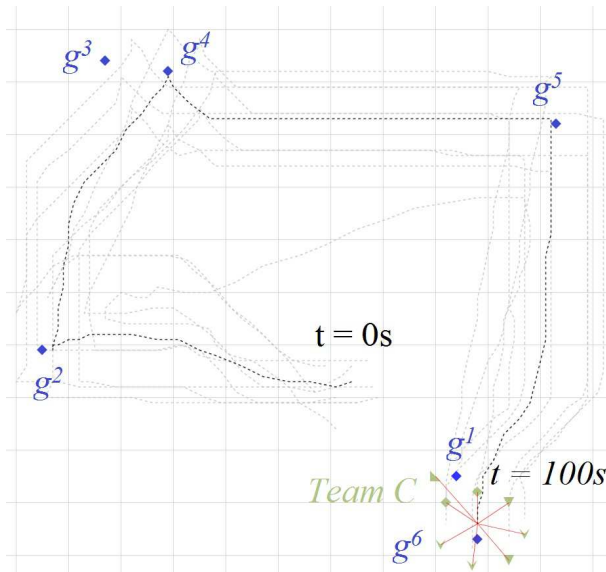



FIGURE 8.8 – Une détection méso d’un scénario complexe (correspondant au schéma 8.9(b)).

8.3.2 Expériences n° 10 : Précision sur divers environnements asymétriques

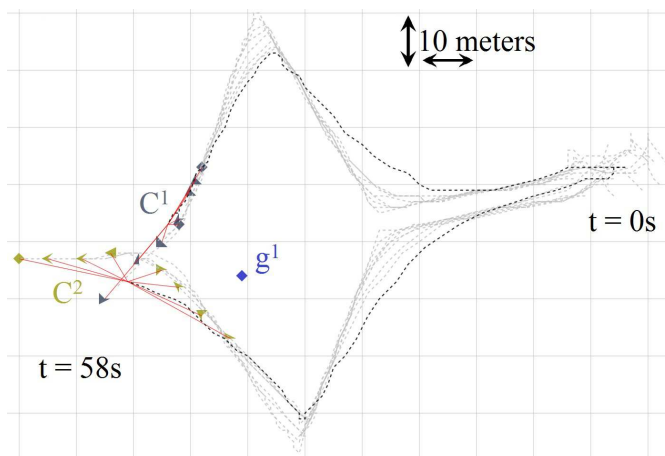
Les illustrations de la Figure 8.9 sont des situations observées qui ont été simulées afin d’obtenir la précision de notre détection des comportements objectivés de groupe. La légende est toujours celle page 124. Pour chaque groupe, les autres entités de la situation (agents seuls, groupes, ou importantes positions) composent l’ensemble des objectifs possibles et sont représentées par les losanges bleus (avec le symbole g^i du $i^{\text{ème}}$ objectif).



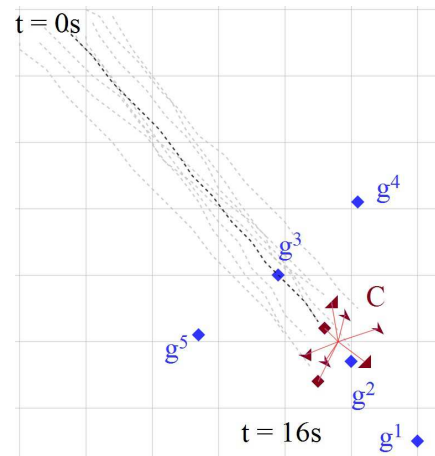
(a) Un groupe est passé au travers de quatre positions importantes tandis qu'il est suivi par une force de sécurité.



(b) Deux groupes se croisent à deux reprises en visitant la zone.



(c) Deux équipes ont évité une zone dangereuse.



(d) Une équipe se dirige vers une infrastructure critique après avoir passé une des trois forces de sécurité.

FIGURE 8.9 – Exemples de scénarios surveillés pour obtenir la précision de la reconnaissance.

Durant les expérimentations, la **qualité** de la détection de comportement est mesurée par le pourcentage :

- ◇ de la **précision** exprimée par $A/(A + C)$;
- ◇ du **rappel (recall)** exprimé par $A/(A + B)$;
- ◇ des **manqués (miss)** exprimés par $B/(A + B)$;
- ◇ et des **fausses alarmes (false alarm)** exprimées par $C/(C + D)$;
- ◇ où ces valeurs correspondent :

- A au nombre de **vrais positifs** : quand le modèle détecté est celui observé ;
 - B au nombre de **vrais négatifs** : aucune détection (i.e. le modèle détecté est celui par défaut $\lambda^{c \rightsquigarrow g}$) puisque ce qui a été observé n'existe pas par les modèles définis et appris ;
 - C au nombre de **faux positifs** : quand le modèle détecté ne correspond pas à celui observé ;
 - D au nombre de **faux négatifs** : aucune détection (i.e. le modèle détecté est celui par défaut $\lambda^{c \rightsquigarrow g}$) alors que ce qui est observé existe parmi les modèles définis et appris.
- En d'autres termes, notre précision est la fréquence des modèles de comportement correctement détecté.

Il y a quelque rare cas où nous observons et détectons un comportement qui chevauche deux modèles appris (e.g. lorsqu'il y a une transition d'un ancien vers un nouveau). Dans ce cas, pour chaque comportement détecté qui correspond à celui observé, nous donnons un point (i.e. la récompense) divisé par le nombre des comportements qui sont observés.

Pour calculer cette précision automatiquement lors de la reconnaissance, nous avons programmé une procédure exhaustive dans notre système de détection. Pour chaque nouveau scénario, notre système nous demande pour chaque nouvelle observation, pour chaque groupe, pour chaque objectif, si le comportement objectivé reconnu est celui observé. Cela nous permet de faire varier les paramètres de décomposition, d'apprentissage et de reconnaissance afin de garder l'ensemble qui nous donne la meilleure précision de détection.

Longueurs de reconnaissance	1	58,06 %							
	CEP	HMM Longueurs d'apprentissage des séquences d'observations							
	2	3	4	5	6	7	8	9	10
2	85,2%	85,8%	84,7%	84,7%	84,69%	84,8%	84,4%	84,6%	83,5%
3	86,9%	86,5%	87,0%	87,0%	87,0%	86,9%	86,5%	86,4%	84,5%
4	87,7%	88,46%	88,2%	86,4%	86,2%	86,1%	86,1%	86,4%	86,0%
5	84,6%	84,6%	85,1%	85,0%	85,7%	85,6%	85,6%	85,9%	85,1%
6	81,3%	81,4%	80,5%	80,6%	80,7%	80,8%	81,2%	81,5%	80,6%
7	77,8%	77,0%	76,5%	76,6%	77,1%	77,3%	77,2%	77,8%	76,4%
8	75,7%	74,8%	73,1%	72,8%	73,3%	73,6%	73,6%	73,7%	73,4%
9	71,4%	71,1%	70,3%	70,4%	70,0%	70,3%	70,3%	70,6%	70,4%
10	68,3%	67,8%	66,1%	66,4%	67,2%	67,4%	67,9%	68,2%	67,5%

TABLEAU 8.1 – Les précisions de l'assignement des comportements objectivés de groupes sur de multiples scénarios (i.e. Figure 8.9) en comparant les CEP et les HMM (en faisant varier les longueurs des séquences d'observations pour l'apprentissage et la reconnaissance).

Le Tableau 8.1 présente les tests pour l'apprentissage et la reconnaissance en faisant varier les longueurs des séquences d'observations de 2 à ∞ (par une méthode d'itération automatique) sur divers scénarios complexes (dont ceux de la Figure 8.9).

- Il affiche les résultats jusqu'aux séquences de longueur 10 pour la reconnaissance et l'apprentissage. En effet, la précision baisse petit à petit en augmentant cette longueur.

- La plus courte longueur des séquences (comme en [2,2] dans le Tableau 8.1) permet de détecter le plus rapidement chaque nouveau comportement objectivé. Toutefois, les observations récentes et bruitées auront plus d'impact sur la détection. L'incertitude et/ou l'incomplétude d'une nouvelle observation réduisent la précision. Par exemple, lorsqu'un groupe évite un obstacle, le système détectera un nouveau comportement, ce qui n'est pas le cas.

○ La solution avec une moyenne longueur de séquence (comme en [5,5]) permet de détecter les comportements actuels même avec des observations bruitées. Cependant, les nouveaux comportements seront détectés seulement après deux nouvelles observations.

✓ Afin d'obtenir la meilleure qualité de détection, les quatre dernières observations (une par seconde) dans les séquences testées (de ces scénarios) nous donnent toujours la plus grande précision (i.e. 88.46% pour [4;3]). De même, pour l'apprentissage des comportements objectivés, les séquences d'observations continues doivent être découpées toutes les trois observations.

✗ La majorité des fausses détections se produisent quand le groupe change son comportement objectivé. Afin d'augmenter la précision à plus de 92%, nous pouvons ajouter des modèles de comportements qui se chevauchent, tels que ceux qui transitent d'un ancien vers un nouveau comportement. Malheureusement, cela augmente à $O(n^2)$ la taille de la librairie des modèles de comportements, le besoin en séquences d'observations à apprendre et le nombre de reconnaissances (i.e. la probabilité à calculer) à effectuer en temps réel.

◇ En plus de la **précision**, nous avons effectué le calcul d'autres indices de qualité de la détection. Par exemple sur la meilleure précision en [4,3], nous avons 99.86% de rappel (*recall*), 0.14% de manqués (*miss*) et 88.94% de fausses alarmes (*false alarm*). Par exemple, 2 observations en reconnaissance et 9 en apprentissage produisent le plus bas taux de fausses alarmes à 77.6% (avec 84.6% de précision, 0.4% de manqués et 99.6% de rappel). Le taux de fausses alarmes décroît avec une plus grande longueur en apprentissage. Mise à part le taux de fausses alarmes, les pourcentages de *recall*, *miss* et sont (à quelques dixièmes) équivalents pour **chaque** cellule du tableau 8.1, donc nous ne les avons pas ajoutés au tableau afin d'éviter de le surcharger. Cela nous indique que notre algorithme assigne constamment au modèle de comportement le plus proche, plutôt que celui vide par défaut. En effet, nous devrions chercher à ce que le modèle de HMM vide soit celui sélectionné quand il y a trop d'incertitude afin de réduire ce fort taux de fausses alarmes.

→ Notre **assignement des comportements objectivés de groupe** réduit l'impact des observations sous incertitude et permet **toujours de détecter** le plus proche modèle parmi ceux appris **après deux observations**.

• Les CEP mettent à jour instantanément l'état actuel du comportement objectivé de groupe, mais sans prise en compte de l'incertitude des nouvelles observations.

✗ Afin d'aider à gérer une situation de crise, la faible précision (58%) indique que les comportements de groupes et leurs objectifs ne sont pas tous détectés par le CEP. Bien sûr, cette précision pourrait être sensiblement augmentée en optimisant les règles.

✓ Lors de la surveillance de foule, la gestion simple d'une énorme quantité de faits par les CEP est fortement utile. Le point important est la capacité des CEP **à gérer les règles par priorité**. Si le système est limité en ressources disponibles (i.e. nombre de calculs, mémoires utilisés,...), alors il ne perdra pas de temps à chercher à détecter des comportements ayant une moindre importance (telle que la mise à jour constante des groupes).

→ Les deux types de résultats nous permettent de **fusionner** les avantages des deux approches. En présence de nouvelles observations, les règles qui déclencheront nos algorithmes de détection par priorité. Les résultats de chaque algorithme seront ajoutés comme nouveaux faits (à propos des groupes et des comportements objectivés).

Une **chose étonnante** s'est produite durant cette expérimentation. Afin d'augmenter la précision, parmi les séquences apprises de chaque comportement, nous avons cherché la présence des séquences les plus différentes de l'ensemble appris. Nous les avons retirés et avons observé une baisse de la précision moyenne de quelques pourcents. Pour comprendre ce qui s'est passé, nous avons alors testé l'appren-

tissage avec des ajouts et/ou des retraits de séquences proches et/ou éloignées. Nous en avons déduit que :

▷ Plus les scénarios observés risquent d'être **simples**, plus les séquences apprises doivent inclure une grande fréquence de séquences **homogènes**. En effet, les comportements y sont plus linéaires à observer.

▷ Plus les scénarios observés risquent d'être **complexes**, plus les séquences apprises doivent inclure une grande fréquence de séquences **hétérogènes**. En effet, les comportements y sont plus erratiques à observer.

▷ Comme notre expérimentation est itérée automatiquement afin d'obtenir deux paramètres nous procurant la meilleure précision (e.g. le Tableau 8.1), nous l'avons mis à jour pour qu'il ne garde que les sous-séquences d'apprentissage qui améliore sa qualité de détection. Pour rappel, chaque séquence d'observation est continue, le système la découpe à intervalles réguliers et apprend chaque sous-séquence. À chaque itération, le système sélectionne les sous-séquences d'apprentissages qu'il teste pour savoir si elles augmentent sa précision. Le résultat a été chaque fois le même, les premières sous-séquences sont retirées, autrement dit les états initiaux du comportement objectif. Nous avons alors une grande fréquence de séquences homogènes, dont la quantité est équivalente aux séquences hétérogènes.

○ Pour chaque modèle de comportement objectif, nous avons effectué un ensemble d'itérations sur les paramètres de décomposition de comportement en séquences d'états. Ces paramètres sont les variables relatives minimales $\delta r^{min} \in s$ qui indiquent une transition minimale afin de différencier deux états successifs (i.e. l'étape 3. dans la section 5.1.2 page 92). Dans notre cas, ce sont en rapport avec la position relative et la vitesse relative de l'état relatif discrétisé. Pour preuve de ce que nous avançons, parmi les scénarios complexes testés, nous obtenons 88.46% de précision maximum avec quelques objectifs mobiles et 89.9% sans objectifs mobiles, alors que notre article [Patricx et al., 2013b] (sur cette même expérience) obtenait un maximum 88.1% de précision sans objectifs mobiles (et sur une longueur de 5 en reconnaissance et 2 en apprentissage). Nous avons ainsi pu vérifier que des objectifs mobiles réduisent la précision quand les comportements ne sont pas parmi ceux appris. Surtout quand ceux-ci sont totalement anormaux (e.g. un groupe qui poursuit une cible mobile, mais n'arrivant pas à la rattraper).

◇ Il est à reconnaître que la précision aurait été grandement améliorée si nous avions effectué du "**surapprentissage**". C'est-à-dire que les comportements appris auraient été extraits des scénarios complexes sur lequel nous effectuons nos tests de précisions de reconnaissance. Nous n'avons pas effectué cette petite fraude. Nos comportements appris sont issus de scénarios simples et nos comportements reconnus sont issus de scénarios complexes, sans aucun mélange.

→ En d'autres termes, en le mettant à jour, **notre système a la capacité d'améliorer sa précision de détection** sur des scénarios complexes (annotés de manière semi-supervisée) en faisant varier, à chaque itération, l'ensemble des paramètres qui servent lors de l'apprentissage, de la reconnaissance, de la décomposition (séquentielle et hiérarchique) des comportements objectifs.

Notre approche nous permet d'obtenir en temps réel une détection des comportements objectifs de groupes. Ces informations de haut niveau sont plus simples à comprendre pour les utilisateurs d'un tel système de surveillance. Néanmoins lors d'une panique collective et tout événement de foule, les informations de comportements déviants peuvent être produites en grande quantité et déclencheront beaucoup d'alertes. Pour aider un utilisateur humain à comprendre ce qui est en train de se passer, nous pouvons ajouter une solution qui utiliserait ses résultats afin de détecter des intentions objectivées. Il suffit d'en ajouter les règles qui déclencheront de tels algorithmes.

Notre évaluation des objectifs et des comportements (section 5.4 page 100) nous permettrait de détecter les intentions objectivées des groupes, notamment pour les classifier en normaux, déviantes (malveillantes et suspicieuses) ou anormaux. La section suivante démontre une utilisation de notre système sur une situation asymétrique.

8.4 Détection de menaces dans un environnement complexe dynamique



FIGURE 8.10 – Un scénario asymétrique dangereux : un kamikaze introuvable parmi la foule paniquée.

Au travers du **projet européen EUSAS** (expliqué en détail dans l'Annexe 9 page 167), nous avons acquis certaines connaissances sur les comportements collectifs sociologiques qui sont produits durant un scénario asymétrique. En utilisant VBS2, nous avons alors simulé un scénario asymétrique dans lequel une foule se déplace dans une rue alors qu'un individu suspicieux y pénètre (i.e. Illustration 8.10) :

- 200 agents sont dispatchés dans différents groupes. Ces groupes sont ainsi composés d'individus ayant des âges et des origines ethniques différentes. Initialement, ils marchent tranquillement dans la rue.
- Chaque groupe comporte un leader qui choisit aléatoirement le lieu d'intérêt où le groupe se rend, selon la configuration de l'environnement.
- Un individu malveillant rentre dans la rue par le côté nord. Il porte une bombe cachée sur son ventre, sous ses vêtements. Il est donc perçu comme seulement suspicieux. Nous utilisons la version 1.4 de VBS2 (resources.bisimulations.com/content/) et celle-ci ne dispose que d'un seul agent ayant l'apparence d'un homme et cachant une bombe sous ses vêtements. Nous ne l'avons pas choisi pour son apparence.
- Lorsqu'un leader d'un groupe aperçoit visuellement l'individu suspicieux (par une réelle fonction de VBS2), celui-ci et son groupe s'enfuient loin de cette menace.
- Les leaders et leurs groupes, qui n'ont pas été en contact visuel avec l'individu, s'étonnent des groupes qui se mettent à courir dans tous les sens. Toutefois, plus il y a de groupes qui s'en

éloignent, plus l'individu sera aperçu par les autres groupes. Au contraire, plus l'individu se cache parmi les groupes en mouvement de panique, moins les autres groupes l'apercevront.

- Un journaliste est au milieu de la foule et est la cible de la menace. La menace cherche à faire exploser son dispositif quand il atteindra sa cible.
- Le journaliste aperçoit les groupes qui courent dans tous les sens et cherche à en connaître la raison. Il ne le comprend qu'au dernier instant en apercevant près de lui le *kamikaze* et son dernier acte.

Un instant du scénario asymétrique est présenté dans l'illustration 8.10. L'aperçu de cette situation est celui du joueur *journaliste*. Le scénario est conçu de manière à ce que le journaliste ne s'aperçoive qu'au dernier moment de la menace et qu'il en est la cible. Pendant le scénario, la foule n'est pas paniquée, seuls quelques groupes sont effrayés, ce qui rend plus difficile l'**évaluation de la situation**.

Dans **notre système de détection multi-agents micro-méso-macro**, l'**agent macro** va rapidement identifier les comportements collectifs de panique et déclencher une alerte s'il suspecte la présence de menaces parmi la foule. Toutefois, ce n'est pas suffisant pour les forces de sécurité. Il leur faut un moyen d'identifier les agents malveillants et dans ce cas, leurs cibles à long terme. Les **agents méso** vont alors être utilisés pour reconnaître les comportements objectivés en fonction des objectifs de la situation. En se basant sur les résultats de comportements objectivés déviants des groupes, les **agents micro** vont évaluer les intentions pour nous permettre d'identifier l'agent menaçant et sa cible. C'est le propos de l'expérience n° 11 suivante.


8.4.1 Expériences n° 11 : Identification d'un agent menaçant parmi une foule

La détection des comportements objectivés évalués de groupe (i.e. section 5.4.1 page 101) est appliquée afin de détecter :


- ▷ **l'intention** $\phi^{\Leftarrow g^j \Rightarrow}$ des groupes s'enfuyant d'un objectif spécifique parmi la foule (i.e. l'objectif est alors une menace non détectable par le système de surveillance) ;
- ▷ **l'intention** $\phi^{c^i \rightarrow g^j}$ d'un groupe qui continue son mouvement pour atteindre un objectif à long terme.
- Afin d'identifier $\phi^{\Leftarrow g^j \Rightarrow}$, nous vérifions pour chaque objectif, si son **intention évaluée** $V_{t-T,t}^{\phi^{\Leftarrow g^j \Rightarrow}, C^i}$ est anormalement haute en utilisant une distribution qui donne une valeur positive quand des groupes contournent et/ou s'éloignent de l'objectif, sinon une valeur négative : $V(\{\lambda^{C^i \leftarrow g^j}, \lambda^{C^i \circ g^j}, \lambda^{C^i \rightsquigarrow g^j}, \lambda^{C^i \leftrightarrow g^j}, \lambda^{C^i \rightarrow g^j}\}) = \{1, \frac{1}{2}, 0, -\frac{1}{2}, -1\}$.
- Et si $\phi^{c^i \rightarrow g^j}$ l'objectif à long terme g^j du groupe c^i est identifié par la plus haute **intention évaluée** $V_{t-T,t}^{\phi^{c^i \rightarrow g^j}}$ en utilisant la distribution : $V(\{\lambda^{c^i \rightarrow g^j}, \lambda^{c^i \circ g^j}, \lambda^{c^i \rightsquigarrow g^j}, \lambda^{c^i \leftrightarrow g^j}, \lambda^{c^i \leftarrow g^j}\}) = \{1, \frac{1}{2}, 0, -\frac{1}{2}, -1\}$.

Avec ses distributions, chaque **intention évaluée non recherchée** est proche de zéro le long du scénario, et l'**intention évaluée recherchée** est rapidement plus grande que la valeur T (puisque c'est calculé de $T - t$ à t) et est multipliée par le nombre d'objectifs et de groupes (quand l'intention évaluée est la somme de plusieurs intentions évaluées, i.e. l'équation 5.8 page 101).

L'illustration 8.11(c) est la vue 3D d'un instant de la situation. Quelques groupes sont en train de courir loin de la menace. Nous notons que certains ne réalisent pas ce qui se passe et continue d'emprunter leur chemin. Le résultat de l'identification des groupes est illustré dans la Figure 8.11(a). La Figure 8.11(b) présente des résultats de cette évaluation des intentions. Cette vue de la situation est utile pour un analyste. En premier lieu, la menace est détectée en se basant sur les comportements produits



(a) Une vue 2D de la situation confuse. Même en disposant de l'identification des groupes et de leurs mouvements, la surveillance est ingérable.



(b) Il est plus simple de suivre chaque mouvement de groupe. Notre détection des intentions objectivées des groupes révèle qu'il y a des groupes qui évitent et s'éloignent d'une seule et même entité, ainsi que le journaliste est sa cible.



(c) Les gens, qui réalisent la présence du kamikaze, sont en train de courir et s'enfuir du lieu. Ceux qui ne l'ont pas aperçu, continuent leurs mouvements et regardent avec surprise les groupes paniqués.

FIGURE 8.11 – Identification d'un agent menaçant en utilisant les comportements collectifs de la foule.

relativement à cette entité. Les groupes qui n'ont pas aperçu la menace sont en danger et ceci est aussi révélé par leur absence de comportement relatif. Ce résultat permettrait aux forces de sécurité de prédire les groupes en danger et de s'attendre à un nombre de victimes dans le cas où la menace ne peut être stoppée à temps.

Un aspect important de la méthode est que le kamikaze a caché son dispositif explosif et se promène parmi les groupes innocents de manière à ne pas être reconnu par le système de surveillance. S'il reste trop longtemps parmi un groupe, alors ce sera le groupe qui sera considéré comme ayant une intention évaluée menaçante. Cependant, une difficulté de la méthode est de créer une distribution correcte pour évaluer les intentions en fonction de la librairie des comportements objectivés. Chaque intention anormale exécute des comportements spécifiques qui doivent être correctement évalués afin d'éviter les fausses détections. Notre processus a fonctionné pour ce scénario, mais rien n'indique qu'il soit performant pour toutes les situations de même type. C'est pour cette raison que nous avons proposé un processus automatique de **détection des intentions objectivées de groupe** (i.e. section 5.4.2 page 102). Nous espérons que cette innovation pourrait fournir un outil puissant pour aider les forces de sécurité à comprendre la situation et anticiper les comportements des menaces afin d'effectuer la meilleure décision pour la situation. Une citation de Mark Twain illustre que "*It ain't what you don't know that gets you into trouble. It's what you know for sure that just ain't so*", autrement dit "ce qui est à craindre n'est pas ce que l'on ne sait pas, mais ce que l'on croit être vrai et qui ne l'est pas". Dans les situations asymétriques, la moindre information supplémentaire de haut niveau peut changer totalement la donne.

La limite de notre approche pour la détection des intentions objectivées est que nous ne connaissons pas sa précision. Pour l'obtenir, il faudrait produire une grande quantité de différents scénarios asymétriques avec différents types d'événements collectifs. Connaître la précision de la détection des comportements objectivés a déjà été un travail long et fastidieux. C'est un travail à opérer en perspective.

Finalement, lors de la présence **d'infrastructures critiques** et **d'entités vulnérables**, le système peut être utilisé pour estimer les comportements collectifs de la foule (macro), des groupes (méso) et des individus (micro) en se basant seulement sur les comportements relatifs présents et absents de la situation. **Toute notre contribution repose sur les états relatifs.**

8.5 Conclusion

Nous avons illustré que nos **états relatifs** dans les *Hidden Markov Models* peuvent parfaitement détecter, en temps réel, de multiples comportements collectifs, objectifs et intentions des groupes en nous basant sur des observations obtenues d'un processus de fusion de données. Nous avons comparé l'approche proposée en utilisant une approche différente appelée le *Complex Event Processing* et trouvé des résultats tout à fait supérieurs en terme de précision et de tolérance aux bruits. Nous avons toutefois gardé l'avantage des CEP qui est de gérer simplement la grande quantité de faits (i.e. les observations et les résultats de détection) afin de déclencher les règles qui utilisent nos approches de détection pour évaluer la situation.

En perspective sur les environnements asymétriques, nous désirons appliquer notre approche sur un jeu de comportements collectifs anormaux tels que des comportements violents de foules en panique. L'identification automatique et l'apprentissage de nouveaux modèles (de comportements objectivés et d'intentions objectivées), en incluant les rôles, sont envisagés pour obtenir un système complet de détection multi-agents multi-niveau d'observations des comportements collectifs. Le dernier point serait de

créer un système d'aide à la décision pour les forces de sécurité en cas de détection de menace asymétrique, prenant en compte nos résultats de détection.

Quatrième partie

Conclusion et futurs travaux

"Neuf femmes ne peuvent pas faire un bébé en un mois."

Fred Brooks

Bilan des travaux

Cette thèse a été produite afin de répondre au sujet : "*Détection de comportements à travers des modèles multi-agents collaboratifs, appliquée à l'évaluation de la situation, notamment en environnement asymétrique avec des données imprécises et incertaines.*" Nous avons alors étudié les deux domaines de recherche que sont **la simulation et la détection de comportements collectifs** basées sur une approche multi-agents où chaque agent a son propre niveau de modélisation : **micro** (les individus), **méso** (les groupes) ou **macro** (la foule).

Après une étude du point de vue sociologique des théories portant sur les comportements collectifs, nous nous sommes intéressés aux approches d'intelligence artificielle distribuée qui ont modélisé ces théories sur plusieurs niveaux d'observations et d'interactions : **micro, méso ou macro**.

Nous avons participé à la conception et à la démonstration d'un prototype pour le projet européen **EUSAS** (présenté en annexe 9 page 167). Ce projet a été mis en place pour tester et démontrer une nouvelle solution face aux problèmes des événements de foules incontrôlables que rencontrent les forces de sécurité. Il nous a notamment permis de **simuler des scénarios asymétriques** avec des comportements de foule. Les données d'observations de ces comportements nous ont permis de tester les approches de détection.

Les travaux menés pour la simulation sur le niveau micro et sur la détection au niveau macro ont permis deux résultats publiés dans [Patricx et al., 2011] et [Patricx et al., 2012]. Compte tenu de la complexité de surveillance des activités collectives (émergentes ou planifiées), des avantages et des limites rencontrés au niveau macro et micro pour la détection de comportements collectifs, le niveau méso nous a semblé être le meilleur compromis. Le niveau **méso** permet d'avoir une observation moins incertaine (i.e. moins incomplète et/ou moins imprécise) et d'un plus haut niveau d'information.

Autrefois, la limite de la détection était le besoin d'information en qualité et en quantité à propos des agents / entités pistées dans la situation surveillée. Toutefois de nos jours, la généralisation des smartphones (et des téléphones portables) nous permet d'y pallier par la **chronolocalisation** (qui se fusionne parfaitement avec les systèmes de surveillance multi-capteurs déjà existants).

Nous avons vu la possibilité de fusionner les données issues d'un réseau multi-capteurs lors de notre participation au projet européen DEM@CARE présenté dans l'annexe 10 page 181. Nous avons effectué cette fusion de données par du **CEP** (traitement d'événements complexes). Il est en effet doté d'une certaine facilité de gestion de grande quantité d'observations sur nos trois niveaux micro, méso et macro.

Suite à notre état de l'art, nous avons utilisé notre modèle basé sur les **HMM** (modèles de Markov cachés) **pour apprendre, identifier et anticiper** certaines formes de comportements collectifs. Notre système pourrait être utilisé pour prévenir des risques durant des rassemblements sociaux. L'environne-

ment peut être modifié en fonction des résultats de détection des positions récurrentes où se produisent des interactions physiques afin de les réduire. Un système de surveillance pourrait anticiper les mouvements collectifs en temps réel.

Dans un futur proche, nous pourrions adapter ce système en utilisant un *serious game* et tenter de détecter les intentions des groupes. Ces différentes intentions sont supposées être reflétées par différents comportements collectifs. Nous anticipons un comportement, mais pas l'objectif et encore moins l'intention qui l'a déclenché. Cette perspective a été résolue par notre état relatif discrétisé qui ajoute le "pourquoi" dans la modélisation d'un comportement, autrement dit la possible raison qui a produit ce comportement.

Notre étude sur *l'évaluation de la situation dans les environnements asymétriques avec des données incertaines et incomplètes* correspond aux deux niveaux suivant de la **fusion de données** : (1) nous avons évalué les relations entre les entités par une identification des groupes et (2) nous avons anticipé leurs comportements collectifs par l'apprentissage et la reconnaissance des comportements objectivés et des intentions objectivées. Pour ce dernier, nous avons utilisé les modèles de Markov cachés sur les états relatifs discrétisés.

Notre procédé, basé sur **l'état relatif**, une donnée que nous avons créée, nous permet d'obtenir enfin une évaluation de la situation à un plus haut niveau de fusion de données. Nous en évaluons stochastiquement les objectifs et les intentions des groupes identifiés par le simple fait de surveiller leurs comportements collectifs relatifs envers les autres entités de la situation. Sur ce genre de nouveaux résultats, des alertes simples peuvent être produites pour les forces de sécurité et les aider dans leurs décisions.

Nos expérimentations de cette approche sur des scénarios asymétriques simulés dans un serious game nous ont permis de montrer l'efficacité de cette approche. Celle-ci a alors été brevetée dans [Patricx et al., 2013a] et publiée dans [Patricx et al., 2013b]. Notre approche est intéressante pour sa réapplicabilité dans tout type d'environnement asymétrique.

Il ne fait pas de doute que nos approches proposées seraient d'une grande utilité pour les forces de sécurité face à des situations asymétriques de type panique collective. Dans le domaine de la détection des comportements collectifs, que ce soit pour leur identification (et leur classification), leur apprentissage et leur reconnaissance, ou encore leur anticipation, les idées évoluent et nous ont permis les innovations que nous avons présentées. Les comportements collectifs représentent un phénomène qui peut enfin s'expliquer et être géré afin d'en éradiquer ou du moins d'en limiter les effets néfastes.

Perspectives

Cette thèse a produit de nouvelles idées et laissés des portes ouvertes, dont notamment deux d'entre elles.

La première est d'utiliser des ontologies pour décrire les comportements possibles par rapport au type de l'objectif. Le principe serait d'avoir une approche contextuelle de la situation surveillée. Chaque agent et chaque objectif peuvent être caractérisés. Leurs caractéristiques identifiables nous permettraient d'utiliser des ontologies qui décrivent les relations possibles entre chaque type d'entité (agents ou groupes) et chaque type d'objectif. Par exemple, lors de l'évacuation d'urgence d'un stade, le système estimera vers quel endroit un groupe est en train de s'enfuir, et ceci sans considérer les toilettes publiques comme un objectif possible. Une anticipation des menaces est aussi possible : estimer la capacité d'un agent à exécuter un comportement malveillant en fonction de son comportement passé et des ontologies décrivant son type.

La seconde est celle de la fusion de modèles multi-agents du domaine de la planification et de la détection. Nous devons nous concentrer sur le fait de mener à bien la détection des comportements collectifs et les projets européens auxquels nous participions en rapport avec le sujet de thèse. La tentative de créer un modèle reliant les deux domaines n'est restée qu'à l'état de formalisme. Nous allons toutefois le présenter dans la section suivante.

1 Jeux stochastiques cachés

Cette section a pour but de montrer notre dernière perspective : les **jeux stochastiques cachés** (HSG, *hidden stochastic game*). En effet, l'état de l'art nous a prouvé trois choses :

- (1) Les actions coopératives des agents peuvent être planifiées en utilisant les **jeux stochastiques** (*stochastic game*) qui ont servi pour les modéliser ;
- (2) Les comportements individuels peuvent être détectés en utilisant les **modèles de Markov cachés** (HMM, *hidden Markov model*) qui ont servis pour les modéliser ;
- (3) Les comportements collectifs représentent le plus bas niveau de coopération (sans communication directe) entre les agents.

Nous proposons les HSG afin de détecter des comportements multi-agents (i.e. collectifs) hiérarchisés au niveau méso. Chaque comportement collectif est exécuté par un système multi-agents, où chacun de ses agents exécute un comportement unique ou récurrent. En se basant sur les séquences d'états observables des agents, nous pouvons apprendre un HSG pour chaque comportement collectif que nous désirons reconnaître. Une fois les HSG appris (i.e. modélisés), nous les utiliserons pour évaluer la situation

observée. Quand un HSG est reconnu, sa transformation en **jeu stochastique partiellement observable** (POSG, *partially observable stochastic game*) permettrait de créer une décision sur des informations plus complètes.

En imaginant deux équipes opposées - les forces bleues et les forces rouges - si les bleus observent et comprennent la stratégie des rouges, alors ils peuvent plus facilement créer une contre-stratégie. Dans la réalité, il n'est jamais simple de comprendre la stratégie de l'adversaire. Comme ce que disait Mark Twain : "*Ce qui est à craindre n'est pas ce que l'on ne sait pas, mais ce que l'on croit être vrai et qui ne l'est pas*". En d'autres termes, le fait de détecter la stratégie adverse par les HSG nous donne plus d'informations pour notre propre POSG et ainsi, de planifier une meilleure contre-stratégie.

1.1 Notions contextuelles

Nous allons rappeler les jeux stochastiques du point de vue du domaine de la décision afin de les transposer dans celui de la détection. Le principe est de retrouver la décision qui a produit les actions collectives observées. La compréhension des modèles suivants est importante pour comprendre comment nous allons ensuite opérer cette transposition :

- ✘ HMM : le modèle de Markov caché (*hidden Markov model*) $\langle S, A, O, B, \Pi \rangle$;
- ✘ MDP : le processus décisionnel de Markov (*markov decision process*) $\langle S, A, T, R \rangle$;
- ✘ POMDP : le MDP partiellement observable (*Partially Observable MDP*) $\langle S, A, T, R, \Omega, O \rangle$;
- ✘ SG : le jeu stochastique (*stochastic game*) $\langle N, S, A, R, T \rangle$;
- ✘ POSG : le SG partiellement observable (*partially observable SG*) $\langle I, S, A, R, P, O, b^0 \rangle$;

Un SG se définit par le 5-uplet $\langle N, S, A, R, T \rangle$:

- N est le nombre d'agents prenant part au jeu ;
- S est l'ensemble des états où le jeu peut se trouver (décrivant l'état du monde et des agents) ;
- $A = \{A_1, \dots, A_N\}$ est l'ensemble des actions possibles pour tout agent, où A_i est l'ensemble des actions possibles de l'agent i ($A_i = \{a_i^1, \dots, a_i^{|A_i|}\}$) ;
- $R = \{R_1, \dots, R_N\}$ est l'ensemble des fonctions de récompenses R_i de chaque agent i ;
- T est le modèle de transition entre les états selon les actions jointes des agents ;

À chaque étape, chaque agent i a effectué une action basée sur son état actuel s_i et sa politique π_i pour amener le jeu à un nouvel état s' . La politique d'un agent a pu être de deux types : (1) si l'agent a suivi une stratégie pure alors $\Pi_i : S \rightarrow A$, (2) sinon une stratégie mixte selon une distribution de probabilité sur les états $\Pi_i : S \rightarrow [0, 1]^{|A_i|}$. La politique jointe pour chaque agent du jeu est $\vec{\pi} = \{\pi_1, \dots, \pi_N\}$, où $\vec{\pi}(s) = \{\pi_1(s), \dots, \pi_n(s)\}$ est la politique jointe pour l'état s . Dans le jeu, chaque agent i a une utilité immédiate $u_i^s(\vec{\pi}(s)) = R_i(\vec{\pi}(s))$ et l'utilité prévue pour un agent i à l'état s : $U_i^{\vec{\pi}}(s) = u_i^s(\vec{\pi}(s)) + \beta \sum_{\forall s' \in S} T(s, \vec{\pi}(s), s') U_i^{\vec{\pi}}(s')$.

Pour rappel, un SG définit l'ensemble fini des états des agents dans S , où chaque $s_t^i \in S$ est l'état de l'agent i à l'instant t . Ces états incluent les variables externes (comme les variables spatio-temporelles telles que la position, la direction, la vitesse,...) et internes (sa politique, ses désirs / objectifs / intentions,...) de l'agent. Un observateur n'a accès qu'aux observations de ses variables externes, qui n'est que la partie visible de son état s_t^i que nous appelons son état observable o_t^i et correspond à son état caché q_t^i (qui ne peut être que connu par apprentissage). Dans la réalité, les valeurs des variables internes ne peuvent pas être calculées, mais nous pouvons les apprendre préalablement soit à main levée, soit par

un algorithme d'apprentissage. En simulant ces mêmes agents exécutant les comportements qui seront ensuite observés dans la réalité, nous avons accès aux valeurs des variables internes et externes. Un algorithme d'apprentissage va alors calculer la probabilité que tel ensemble de valeurs de variables externes aura probablement tel ensemble de valeurs de variables internes.

Si nous prenons l'exemple d'un agent se déplaçant dans un couloir horizontal décomposé en case : la sortie à droite, la machine à café au milieu et le bureau à gauche. Quand il sort de son bureau, l'action "se déplacer à droite" correspond soit à la politique "sortir", soit "aller prendre un café". L'apprentissage modélise que tels états observables peuvent correspondre stochastiquement à tels états cachés. Lors de l'observation de l'action "se déplacer à droite" entre deux états observables, si la valeur de la variable externe "vélocité" reste constante et ne diminue pas alors la probabilité que ce soit la politique "sortir" est plus forte que celle de "aller prendre un café".

L'agent i connaît son état s_t^i de manière déterministe, mais un observateur externe ne connaît que son état observable o_t^i et peut trouver son état caché q_t^i en sélectionnant celui le plus probable en fonction de o_t^i (après l'apprentissage). Cette probabilité peut être renforcée si elle est établie de manière stochastique (i.e. en utilisant toutes les transitions d'états observables passées issues de chaque action de l'agent). Ainsi un apprentissage stochastique de chaque politique possible (i.e. chaque comportement de l'agent) peut être effectué sur les séquences d'observations quand nous connaissons les séquences d'états cachés qui leur correspondent. C'est ce que fait le HMM (i.e. Section 3.2.1 page 55).




FIGURE 1 – Un exemple de différents HMMs appris

Suite à ce rappel, nous allons présenter notre formalisme du HSG.

1.2 Modèle

Le formalisme du modèle HSG que nous présentons dans cette sous-section transpose le HMM et le POSG en HSG en passant par une étape intermédiaire : le multi-HMM.

A. Multi-HMM pour la détection des possibles comportements d'un agent

Un agent exécute différents comportements, donc différentes séquences d'états qui peuvent être apprises et reconnues par de multiples HMM (i.e. un ensemble de HMM, un par comportement).

Un **M-HMM se définit** par le 6-uplet $\langle J, \langle Q, A, O, B, \Pi \rangle_{j \in J} \rangle$:

- J est un nombre de HMM (comportements) indexés $1, \dots, j, \dots, |J|$ que nous pouvons observer chez un agent.
- Q est un ensemble fini d'états cachés, où q_i est le $i^{\text{ème}}$ état caché ;
- A est un ensemble fini de probabilités de transitions, où $a_{ij} = Pr(s_{t+1} = q_j | s_t = q_i)$ est la probabilité de transition que l'état caché sera q_j après q_i ;
- O est un ensemble fini d'états observables, où o_i est l'état partiellement observable de q_i ;
- B est un ensemble fini de probabilités d'observations, où $b_{ik} = Pr(o_k | q_i)$ est la probabilité d'observer o_k pendant l'état q_i ;
- Π est un ensemble fini de probabilités d'états initiaux, où $\pi_i = Pr(s_0 = q_i)$ est la probabilité d'être initialement dans l'état q_i .

Les ensembles Q , O et B restent les mêmes pour l'agent quelque soit le HMM (contrairement à Π et A dont les probabilités sont définies selon le comportement de l'agent). En conséquence, le M-HMM se définit par le 6-uplet $\langle J, Q, O, B, \langle A, \Pi \rangle_{j \in J} \rangle$. De la même manière, Q , O et B restent les mêmes pour tout agent observé **si seulement si** ils appartiennent à la même catégorie d'entité observable (i.e. comme deux agents **homogènes**, mais pas dans le cas où les deux agents sont un individu et un robot).

À chaque étape, nous observons la transition de l'agent i de o_j vers son nouvel état $o_{j'}$. Le comportement de cet agent (exécuté selon sa politique) peut être retrouvé en utilisant un M-HMM : pour chaque HMM appris, nous calculons une probabilité jointe sur les agents de I par l'équation $Pr(HMM_i | O_t^I)$. Cette équation donne la probabilité que la séquence d'observations $O_t = \{O_1, \dots, O_t\}$ puisse être produite par le HMM_i (et est résolue en utilisant l'algorithme de *Forward-Backward*). Le HMM sélectionné est celui ayant obtenu la plus haute probabilité.

Nous allons maintenant transposer le M-HMM (applicable aux multiples comportements possibles d'un agent) au HSG (applicable aux multiples comportements possibles d'un système multi-agents).

B. HSG pour la détection des possibles comportements multi-agents

Un HSG (jeu stochastique caché) est paramétrable soit à main levée, soit par une méthode d'apprentissage automatique. Il existe déjà des algorithmes pour paramétrer un HMM selon le comportement d'un agent (ses décisions par rapport à son état et sa politique). Il reste à les modifier pour l'apprentissage d'une configuration de jeu stochastique. C'est-à-dire que les agents ayant participé au jeu ont effectué leurs décisions (et donc les actions observées) selon les états et les politiques de tous les agents pour maximiser la récompense (personnel et/ou du groupe) (afin de maximiser l'utilité de l'action).

Si nous nous basons sur les informations spatio-temporelles (positions, directions, vitesses,...) des agents pour définir les états cachés, dans le cas où :

- ▷ les agents sont **homogènes** alors le HSG est défini par le 6-uplet $\langle I, Q, O, B, \Pi, A \rangle$;
- ▷ les agents sont **hétérogènes** alors le HSG est défini par le 6-uplet $\langle I, Q, O, \langle A, B, \Pi \rangle^{i \in I} \rangle$.

Pour exemple d'hétérogénéité, un agent et un robot auront les mêmes ensembles possibles d'états cachés et observables, mais la probabilité d'observer l'état observable d'un agent selon son état caché est différente pour les deux, puisque le robot n'a pas la même présence spatiale qu'un individu.

Un **HSG se définit** par le 6-uplet $\langle I, Q, O, B, \Pi, A \rangle$:

- I est un ensemble fini d'agents (appartenant à la même catégorie d'entité observable) indexés $1, \dots, i, \dots, |I|$ observé pendant le jeu. L'homogénéisation de la catégorie des agents fait que les en-

sembles d'états cachés, d'états observables, des probabilités d'observations et de transitions sont identiques pour chaque agent i , donc nous pouvons définir :

- $Q = \{Q^1, \dots, Q^{|Q|}\}$ est un ensemble fini d'états cachés où le jeu peut être (décrivant l'état caché du monde et des agents), où Q^J décrit le $J^{\text{ème}}$ état caché possible du jeu, et où $q_j^i = q_j$ décrit le $j^{\text{ème}}$ état caché dans lequel peut être tout agent i ;
- $O = \{O^1, \dots, O^{|Q|}\}$ est un ensemble fini d'états observables du jeu, où O^I est l'état observable du jeu quand il est dans l'état caché Q^J , où $o_j^i = o_j$ est l'état observable de l'état q_j de tout agent i ;
- B est un ensemble fini de probabilités d'observations du jeu, où $b^{JK} = Pr(O^K|Q^J)$ est la probabilité d'observer l'état observable O^K si le jeu est dans l'état caché Q^J , où $b_{jk}^i = Pr(o_k|q_j)$ est la probabilité d'observer o_k si tout agent i serait dans q_j ;
- Π est un ensemble fini de probabilités d'états initiaux du jeu, où $\pi^J = Pr(S_0 = Q^J)$ est la probabilité que le jeu se trouve initialement dans Q^J , où $\pi_j^i = \pi_j = Pr(s_0 = q_j)$ est la probabilité que tout agent i se trouve initialement dans q_j ;
- A est un ensemble fini de probabilités de transitions d'états cachés, où $a^{IL} = Pr(S_{t+1} = Q^L|S_t = Q^I)$ est la probabilité de transition de Q^I vers Q^L (lors d'une action jointe par exemple), où $a_{jk}^i = a_{jk} = Pr(s_{t+1} = q_k|s_t = q_j)$ est la probabilité de transition de q_j vers q_k pour tout agent i ;

Ces contraintes sont les suivantes (adaptés de celle d'un HMM, mais celles d'un SG devront être aussi adaptés) :

$$\begin{aligned} \forall i \in I, \forall j \in Q^i, \sum_{k=0}^{|Q^i|} a_{jk}^i &= 1 & \forall Q^I \in Q, \sum_{K=0}^{|Q|} a^{IK} &= 1 \\ \forall i \in I, \forall j \in Q^i, \sum_{k=0}^{|Q^i|} b_{jk}^i &= 1 & \forall Q^I \in Q, \sum_{K=0}^{|Q|} b^{IK} &= 1 \\ \forall i \in I, \sum_{l=0}^{|Q^i|} \pi_l^i &= 1 & \sum_{I=0}^{|Q|} \pi^I &= 1. \end{aligned}$$

À chaque étape, nous observons la transition de chaque agent i de o_j^i vers son nouvel état $o_{j'}^i$, amenant le jeu stochastique caché de Q^J à $Q^{J'}$. Le comportement collectif des agents peut être retrouvé en utilisant un Multi-HSG : pour chaque HSG $_i$ appris, nous calculons une probabilité jointe sur les agents de I par l'équation $Pr(HSG_i|O_t^I)$. Elle donne la probabilité que la séquence d'observation $O_t = \{O_1, \dots, O_t\}$ pourrait être produit par le HSG $_i$ (résolu en utilisant l'algorithme de Forward-Backward comme pour le HMM). Le HSG ayant obtenu la plus haute probabilité est sélectionné comme étant celui observé.

1.3 Conclusion

Nous pouvons ainsi définir un HSG pour chaque comportement collectif (parmi un système multi-agents) que nous cherchons à détecter (ex : une équipe de soldats / robots opérant une mission de reconnaissance où chacun effectue ses actions pour maximiser l'atteinte de l'objectif de cette mission en un moindre temps et coût). D'une autre manière, il peut être détecté les comportements coopératifs et non coopératifs parmi les agents par la détection de leurs actions jointes.

Il reste toutefois un pas à franchir par l'implémentation des HSG. Notamment, il sera question de trouver des méthodes approximatives pour l'apprentissage et / ou la reconnaissance afin de réduire la complexité si celle-ci empêche une application en temps réel.

Bibliographie

- [Adams, 2007] Adams, J. A. (2007). Unmanned vehicle situation awareness : A path forward. In *American Society of Naval Engineers Human-System Integration Symposium*. Annapolis, Maryland, USA. 35
- [Australia, 2008] Australia, B. (2008). Virtual battle space (vbs2). Retrieved from <http://virtualbattlespace.vbs2.com>. 168
- [Avrahami-Zilberbrand, 2009] Avrahami-Zilberbrand, D. (2009). *Efficient Hybrid Algorithms for Plan Recognition and Detection of Suspicious and Anomalous Behavior*. PhD thesis, Citeseer. 49
- [Ayers and Shah, 2001] Ayers, D. and Shah, M. (2001). Monitoring human behavior from video taken in an office environment. *Image and Vision Computing*, 19(12) :833–846. 54, 57
- [Banerjee et al., 2010] Banerjee, B., Kraemer, L., and Lyle, J. (2010). Multi-agent plan recognition : Formalization and algorithms. In *Proceedings of AAAI*, volume 10, pages 1059–1064. 45
- [Beckers et al., 1994] Beckers, R., Holland, O., and Deneubourg, J. (1994). From local actions to global tasks : Stigmergy and collective robotics. In *Artificial life IV*, volume 181, page 189. Citeseer. 26
- [Bellenger, 2013] Bellenger, A. (2013). *Semantic Decision Support for Information Fusion Applications*. PhD thesis, INSA de Rouen. 187
- [Bellenger et al., 2011] Bellenger, A., Lerouvreur, X., Gatepaille, S., Abdulrab, H., and Kotowicz, J.-P. (2011). An information fusion semantic and service enablement platform : The fusionlab approach. In *Information Fusion (FUSION), 2011 Proceedings of the 14th International Conference on*, pages 1–8. IEEE. 187
- [Blasch, 2008] Blasch, E. (2008). Introduction to level 5 fusion : the role of the user. *Handbook of multisensory data fusion : theory and practice*, 2 :503–537. 38
- [Blasch et al., 2012] Blasch, E. P., Lambert, D. A., Valin, P., Kokar, M. M., Llinas, J., Das, S., Chong, C., and Shahbazian, E. (2012). High level information fusion (hlif) : Survey of models, issues, and grand challenges. *Aerospace and Electronic Systems Magazine, IEEE*, 27(9) :4–20. 39, 40
- [Blasch and Plano, 2002] Blasch, E. P. and Plano, S. (2002). Jdl level 5 fusion model : user refinement issues and applications in group tracking. In *AeroSense 2002*, pages 270–279. International Society for Optics and Photonics. 38
- [Blumer, 1951] Blumer, H. (1951). Collective behavior. *New outline of the principles of sociology*, pages 166–222. 15
- [Boussard, 2008] Boussard, M. (2008). *Planification multi-agents multi-objectifs : modele et algorithme*. PhD thesis, Universite de Caen. 26, 29
- [Bowman, 2004] Bowman, C. (2004). The dual node network (dnn) data fusion & resource management (df&rm) architecture. In *AIAA Intelligent Systems Conference, Chicago*. 50, 134

- [Bratman et al., 1998] Bratman, M., Israel, D., and Pollock, M. (1998). Plan and resource-bounded practical reasoning. *Computational Intelligence*, 4(4). 25
- [Bui, 2002] Bui, H. (2002). Efficient approximate inference for online probabilistic plan recognition. In *AAAI Fall Symposium on Intent Inference for Users, Teams and Adversaries*. 61, 71
- [Bui et al., 2004] Bui, H., Phung, D., and Venkatesh, S. (2004). Hierarchical hidden markov models with general state hierarchy. In *Proceedings Of The National Conference On Artificial Intelligence*, pages 324–329. Menlo Park, CA ; Cambridge, MA ; London ; AAAI Press ; MIT Press ; 1999. 62, 69
- [Bui et al., 2002] Bui, H., Venkatesh, S., and West, G. (2002). Policy recognition in the abstract hidden markov model. *Journal of Artificial Intelligence Research*, 17(1) :451–499. 61, 68
- [Canada and Hanna, 1995] Canada, E. P. and Hanna, J. (1995). *Emergency Preparedness Guidelines for Mass, Crowd-Intensive Events*. Emergency Preparedness Canada. 85
- [Canu et al., 2008] Canu, A., Boussard, M., and Mouaddib, A.-I. (2008). Stackelberg equilibrium in robot platooning. *ICAPS'08 Multiagent Planning Workshop*. 46
- [Cao et al., 1997] Cao, Y. U., Fukunaga, A. S., and Kahng, A. B. (1997). Cooperative mobile robotics : Antecedents and directions. *Auton. Robots*, 4(1) :7–27. 21, 26
- [Chang et al., 2011] Chang, M., Krahnstoever, N., and Ge, W. (2011). Probabilistic group-level motion analysis and scenario recognition. In *Computer Vision (ICCV), 2011 IEEE International Conference on*, pages 747–754. IEEE. 44, 134
- [Charniak Robert et al., 1993] Charniak Robert, P. et al. (1993). A bayesian model of plan recognition. *Artificial Intelligence*, 64(1) :53–79. 54
- [Choi and Kim, 2009] Choi, J. and Kim, K. (2009). Inverse reinforcement learning in partially observable environments. In *Proceedings of the 21st International Joint Conference on Artificial Intelligence (IJCAI)*, pages 1028–1033. 54
- [Clément-Noguier, 2003] Clément-Noguier, S. (2003). Sécurité du fort contre asymétrie du faible. *Revue internationale et stratégique*, (3) :89–96. 32
- [Cupillard et al., 2002] Cupillard, F., Brémond, F., and Thonnat, M. (2002). Group behavior recognition with multiple cameras. In *Applications of Computer Vision, 2002.(WACV 2002). Proceedings. Sixth IEEE Workshop on*, pages 177–183. IEEE. 41, 43
- [Duong et al., 2005] Duong, T., Bui, H., Phung, D., and Venkatesh, S. (2005). Activity recognition and abnormality detection with the switching hidden semi-markov model. In *Computer Vision and Pattern Recognition, 2005. CVPR 2005. IEEE Computer Society Conference on*, volume 1, pages 838–845. IEEE. 62, 69
- [Durfee et al., 1987] Durfee, E., Lesser, V., and Corkill, D. (1987). Coherent cooperation among communicating problem solvers. *IEEE TRANS. COMP.*, 100(11). 25
- [Endsley, 1995] Endsley, M. (1995). Toward a theory of situation awareness in dynamic systems. *Human Factors : The Journal of the Human Factors and Ergonomics Society*, 37(1) :32–64. 34, 35
- [Endsley, 1997] Endsley, M. (1997). Automation and situation awareness : The accident at cali, columbia. In *In Proceedings of the 9th International Symposium on Aviation Psychology*. 34
- [Fallah et al., 1998] Fallah, A., Haddad, S., and Mazouzi, H. (1998). Observation répartie et analyse des interactions dans un système multi-agents. *Proc. JFIADSMASMA'98*, pages 281–294. 83
- [Ferber, 1995] Ferber, J. (1995). *Les systemes multi-agents : vers une intelligence collective*. InterEditions Paris. 24

-
- [Festinger, 1954] Festinger, L. (1954). A theory of social comparison processes. *Human Relations*, 7 :117–140. 27
- [Fiske, 1993] Fiske, A. (1993). *Structures of social life : The four elementary forms of human relations : Communal sharing, authority ranking, equality matching, market pricing*. Free Pr. 25
- [Fiske, 2000] Fiske, A. (2000). Complementarity theory : Why human social capacities evolved to require cultural complements. *Personality and Social Psychology Review*, 4(1) :76. 25
- [Fortmann et al., 1980] Fortmann, T., Bar-Shalom, Y., and Scheffe, M. (1980). Multi-target tracking using joint probabilistic data association. In *1980 19th IEEE Conference on Decision and Control including the Symposium on Adaptive Processes*, volume 19. 36
- [Fridman and Kaminka, 2007] Fridman, N. and Kaminka, G. (2007). Modeling imitational behavior via social comparison theory. In *Intelligent Virtual Agents*, pages 377–378. Springer. 26, 27, 28
- [Fruin, 1993] Fruin, J. (1993). The causes and prevention of crowd disasters. *Engineering for crowd safety*. Elsevier, New York. 85
- [Gaitanis et al.,] Gaitanis, K., Gemo, M., Vybornova, O., Ruiz, D., Moncarey, R., and Macq, B. Cooperative team behaviour recognition for multimodal fusion. 57, 71
- [Gaitanis and Macq, 2008] Gaitanis, K. and Macq, B. (2008). Group behavior recognition for gesture analysis. *Circuits and Systems for Video Technology, IEEE Transactions on*, 18(2) :211–222. 61, 72
- [Galata et al., 2001] Galata, A., Johnson, N., and Hogg, D. (2001). Learning variable-length markov models of behavior. *Computer Vision and Image Understanding*, 81(3) :398–413. 64
- [Giannotti and Trasarti, 2008] Giannotti, F. and Trasarti, R. (2008). Mobility, data mining and privacy : The geopkdd paradigm. 40
- [Giannotti et al., 2008] Giannotti, G., Giannotti, F., and Pedreschi, D. (2008). *Mobility, data mining and privacy : Geographic knowledge discovery*. Springer. 40
- [Giersich et al., 2007] Giersich, M., Forbrig, P., Fuchs, G., Kirste, T., Reichart, D., and Schumann, H. (2007). Towards an integrated approach for task modeling and human behavior recognition. *Human-Computer Interaction. Interaction Design and Usability*, pages 1109–1118. 55
- [Gong and Xiang, 2003] Gong, S. and Xiang, T. (2003). Recognition of group activities using dynamic probabilistic networks. In *Computer Vision, 2003. Proceedings. Ninth IEEE International Conference on*, pages 742–749. IEEE. 57, 59, 64, 65
- [Grasse, 1959] Grasse, P. (1959). La reconstruction du nid et les coordinations inter-individuelles chez *bellicositermes natalensis* et *cubitermes* sp : La théorie de la stigmergie : Essai d’interprétation du comportement des termites constructeurs. *Insectes Sociaux*, 6 :41–82. 26
- [Hall, 1974] Hall, E. T. (1974). *Handbook for proxemic research*. Society for the Anthropology of Visual Communication Washington, DC. 19
- [Han and Veloso, 2000] Han, K. and Veloso, M. (2000). Automated robot behavior recognition. In *Robotics Research-International Symposium-*, volume 9, pages 249–256. Citeseer. 57, 60, 63
- [Helbing et al., 2000] Helbing, D., Farkas, I., and Vicsek, T. (2000). Simulating dynamical features of escape panic. *Nature*, 407(6803) :487–490. 26, 27
- [Herman, 1997] Herman, P. (1997). Asymmetric warfare : Sizing the threat. *Low Intensity Conflict and Law Enforcement*, 6 :176–183. 33
- [Hicks et al., 2004] Hicks, J. D., Myers, G., Stoyen, A., and Zhu, Q. (2004). Bayesian-game modeling of c2 decision making in submarine battle-space situation awareness. In *In Proc. of Command and Control Research and Technology Symposium*. 35

- [Hluchy et al., 2011] Hluchy, L., Kvassay, M., Dlugolinsky, S., Schneider, B., Bracker, H., Kryza, B., and Kitowski, J. (2011). Handling internal complexity in highly realistic agent-based models of human behaviour. In *Applied Computational Intelligence and Informatics (SACI), 2011 6th IEEE International Symposium on*, pages 11–16. IEEE. 168
- [Hluchý et al., 2012] Hluchý, L., Kvassay, M., Dlugolinský, Š., Schneider, B., Bracker, H., Kryza, B., and Kitowski, J. (2012). Towards more realistic human behaviour simulation : Modelling concept, deriving ontology and semantic framework. *Applied Computational Intelligence in Engineering and Information Technology*, pages 1–17. 168
- [Horling and Lesser, 2005] Horling, B. and Lesser, V. (2005). A survey of multi-agent organizational paradigms. *The Knowledge Engineering Review*, 19(04) :281–316. 25
- [Ivanov and Bobick, 2000] Ivanov, Y. and Bobick, A. (2000). Recognition of visual activities and interactions by stochastic parsing. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 22(8) :852–872. 68
- [JDL, 1991] JDL (1991). Data fusion lexicon. 38
- [Kaluža et al., 2012] Kaluža, B., Kaminka, G. A., and Tambe, M. (2012). Detection of suspicious behavior from a sparse set of multiagent interactions. In *Proceedings of the 11th International Conference on Autonomous Agents and Multiagent Systems-Volume 2*, pages 955–964. International Foundation for Autonomous Agents and Multiagent Systems. 48, 49
- [Killian and Turner, 1972] Killian, L. and Turner, R. (1972). Collective behavior. *Englewood Cliffs*. 15, 16
- [Kis, 1971] Kis, T. (1971). État des travaux sur la problématique de la convergence : théories et hypothèses. *Études internationales*, 2(3). 16
- [Kitani et al., 2005] Kitani, K., Sato, Y., and Sugimoto, A. (2005). Deleted interpolation using a hierarchical bayesian grammar network for recognizing human activity. In *2005 IEEE International Workshop on Visual Surveillance and Performance Evaluation of Tracking and Surveillance*, pages 239–246. IEEE. 68
- [Kitani et al., 2006] Kitani, K., Sato, Y., and Sugimoto, A. (2006). An mdl approach to learning activity grammars. *Proceedings of the Korea-Japan Joint Workshop on Pattern Recognition(KJPR 2006)*, 106(376) :19–24. 67, 68
- [Kristensen and May, 1996] Kristensen, B. B. and May, D. C. (1996). Activities : Abstractions for collective behavior. In *ECOOP'96-Object-Oriented Programming*, pages 472–501. Springer. 90
- [Krol et al., 2012] Krol, D., Kryza, B., Wrzeszcz, M., Dutka, L., and Kitowski, J. (2012). Elastic infrastructure for interactive data farming experiments. *Procedia Computer Science*, 9 :206–215. 169
- [Kryza et al., 2012] Kryza, B., Król, D., Wrzeszcz, M., Dutka, Ł., and Kitowski, J. (2012). Interactive cloud data farming environment for military mission planning support. *Computer Science*, 13(3) :89–100. 169
- [Kvassay et al., 2011] Kvassay, M., Hluchy, L., Kryza, B., Kitowski, J., Seleng, M., Dlugolinsky ?, S., and Laclavík, M. (2011). Combining object-oriented and ontology-based approaches in human behaviour modelling. In *Applied Machine Intelligence and Informatics (SAMI), 2011 IEEE 9th International Symposium on*, pages 177–182. IEEE. 168
- [Kvassay et al., 2013] Kvassay, M., Hluchy, L., and Schneider, B. (2013). Summarizing the behaviour of complex dynamic systems. In *Applied Machine Intelligence and Informatics (SAMI), 2013 IEEE 11th International Symposium on*, pages 15–20. IEEE. 168

-
- [Kvassay et al., 2012] Kvassay, M., Hluchy, L., Schneider, B., and Bracker, H. (2012). Towards causal analysis of data from human behaviour simulations. In *Logistics and Industrial Informatics (LINDI), 2012 4th IEEE International Symposium on*, pages 41–46. IEEE. 168
- [Laclavík et al., 2012] Laclavík, M., Dlugolinský, Š., Šeleng, M., Kvassay, M., Schneider, B., Bracker, H., Wrzeszcz, M., Kitowski, J., and Hluchý, L. (2012). Agent-based simulation platform evaluation in the context of human behavior modeling. *Advanced Agent Technology*, pages 396–410. 168
- [Lau et al., 2010] Lau, B., Arras, K. O., and Burgard, W. (2010). Multi-model hypothesis group tracking and group size estimation. *International Journal of Social Robotics*, 2(1) :19–30. 43
- [Le Bon, 1900] Le Bon, G. (1900). *Psychologie des foules*. F. Alcan. 14
- [Liang and Xiangsui, 1999] Liang, Q. and Xiangsui, W. (1999). *Unrestricted warfare*. Citeseer. 32
- [Liao et al., 2007] Liao, L., Fox, D., and Kautz, H. (2007). Hierarchical conditional random fields for gps-based activity recognition. *Robotics Research*, pages 487–506. 54
- [Liggins et al., 2008] Liggins, M., Hall, D., and Llinas, J. (2008). *Handbook of multisensor data fusion : theory and practice*. CRC. 38, 40
- [Liu and Chua, 2003] Liu, X. and Chua, C. (2003). Multi-agent activity recognition using observation decomposed hidden markov model. *Computer Vision Systems*, pages 247–256. 60, 64
- [Llinas et al., 2004] Llinas, J., Bowman, C., Rogova, G., Steinberg, A., Waltz, E., and White, F. (2004). Revisiting the jdl data fusion model ii. Technical report, DTIC Document. 38
- [Luckham, 2001] Luckham, D. (2001). *The power of events : an introduction to complex event processing in distributed enterprise systems*. Addison-Wesley Longman Publishing Co., Inc. 51, 134
- [Luotsinen, 2007] Luotsinen, L. (2007). *Recognizing teamwork activity in observations of embodied agents*. PhD thesis, University Microfilms International, P. O. Box 1764, Ann Arbor, MI, 48106, USA. 33, 45
- [Luotsinen and Boloni, 2008] Luotsinen, L. and Boloni, L. (2008). Role-based teamwork activity recognition in observations of embodied agent actions. In *Proceedings of the 7th international joint conference on Autonomous agents and multiagent systems-Volume 2*, pages 567–574. International Foundation for Autonomous Agents and Multiagent Systems. 45, 47, 48
- [Luotsinen et al., 2007] Luotsinen, L., Fernlund, H., and Bölöni, L. (2007). Automatic annotation of team actions in observations of embodied agents. In *Proceedings of the 6th international joint conference on Autonomous agents and multiagent systems*, page 9. ACM. 33
- [Mataric, 1993] Mataric, M. (1993). Designing emergent behaviors : From local interactions to collective intelligence. In *From Animals to Animats 2 : Int. Conf. on Simulation of Adaptive Behavior*, pages 423–441. 21
- [Nguyen, 2003] Nguyen, N. (2003). *Recognising Human Behaviours in Complex Environments*. PhD thesis. 71
- [Nguyen and Venkatesh, 2005] Nguyen, N. and Venkatesh, S. (2005). Discovery of activity structures using the hierarchical hidden markov model. In *British Machine Vision Conference*, pages 409–418. 70
- [Nguyen et al., 2005] Nguyen, N., Venkatesh, S., and Bui, H. (2005). Recognising behaviours of multiple people with hierarchical probabilistic model and statistical data association. In *British Machine Vision Conference*. 62, 69, 70
- [Nguyen et al., 2004] Nguyen, N., Venkatesh, S., West, G., and Bui, H. (2004). Learning people movement model from multiple cameras for behaviour recognition. *Structural, Syntactic, and Statistical Pattern Recognition*, pages 315–324. 71

- [Oliver et al., 2002] Oliver, N., Horvitz, E., and Garg, A. (2002). Layered representations for human activity recognition. In *Multimodal Interfaces, 2002. Proceedings. Fourth IEEE International Conference on*, pages 3–8. IEEE. 60, 64
- [Oliver et al., 2000] Oliver, N., Rosario, B., and Pentland, A. (2000). A bayesian computer vision system for modeling human interactions. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 22(8) :831–843. 57, 60, 65
- [Pannetier, 2006] Pannetier, B. (2006). *Fusion de données pour la surveillance du champ de bataille*. PhD thesis, Université Joseph Fourier - Grenoble 1. 37
- [Park, 1904] Park, R. (1904). *Masse und publikum : Eine methodologische und soziologische untersuchung...* Buchdruckerei Lack & Grunau. 15
- [Patricx et al., 2011] Patricx, J., Mouaddib, A., and Gatepaille, S. (2011). Detection of primitive collective behaviors in a crowd panic simulation based on a multi-agent approach. *Proceedings of the International Conference on Swarm Intelligence - Theoretical advances and real world applications (EISTI, Cergy, France)*. 21, 87, 149
- [Patricx et al., 2012] Patricx, J., Mouaddib, A., and Gatepaille, S. (2012). Detection of primitive collective behaviours in a crowd panic simulation based on multi-agent approach. *International Journal of Swarm Intelligence Research (IJSIR)*, 3(3) :50–65. 87, 89, 149
- [Patricx et al., 2013a] Patricx, J., Mouaddib, A.-I., and Le Gloannec, S. (2013a). Patent on detection of groups of entities their group behaviors and their goals using their relative behaviors. 89, 90, 150
- [Patricx et al., 2013b] Patricx, J., Mouaddib, A.-I., Le Gloannec, S., Stampouli, D., and Contat, M. (2013b). Discrete relative states to learn and recognize goal-based behaviors of groups. In Ito, Jonker, G. and (eds.), S., editors, *Proceedings of the 12th International Conference on Autonomous Agents and Multiagent Systems (AAMAS 2013)*, Saint Paul, Minnesota, USA. International Foundation for Autonomous Agents and Multiagent Systems. 89, 90, 140, 150
- [Poisvert et al., 2010] Poisvert, R., Quillet, J.-C., Wartelle, C., Charpillat, F., Simonin, O., Glad, A., Legras, F., and Raynal, P. (2010). Smaart (système multi-agents appliqué à l’auto-organisation et à la reconnaissance du théâtre. Rapport de synthèse, Alyotech Technologies. 29
- [Pynadath and Wellman, 1998] Pynadath, D. and Wellman, M. (1998). Generalized queries on probabilistic context-free grammars. *Pattern Analysis and Machine Intelligence, IEEE Transactions on*, 20(1) :65–77. 67
- [Pynadath and Wellman, 2000] Pynadath, D. and Wellman, M. (2000). Probabilistic state-dependent grammars for plan recognition. In *Proceedings of the 16th Conference on Uncertainty in Artificial Intelligence*, pages 507–514. Citeseer. 68
- [Rabiner, 1989] Rabiner, L. (1989). A tutorial on hidden markov models and selected applications in speech recognition. *Proceedings of the IEEE*, 77(2) :257–286. 56
- [Rabiner and Juang, 1986] Rabiner, L. and Juang, B. (1986). An introduction to hidden markov models. *ASSP Magazine, IEEE*, 3(1) :4–16. 55, 56, 132
- [Rao and Georgeff, 1997] Rao, A. and Georgeff, M. (1997). Modeling rational agents within a bdi-architecture. *Readings in agents*, pages 317–328. 25
- [Reynolds, 1987] Reynolds, C. (1987). Flocks, herds and schools : A distributed behavioral model. In *Proceedings of the 14th annual conference on Computer graphics and interactive techniques*, pages 25–34. ACM. 29, 46
- [Russell and Norvig, 2003] Russell, S. and Norvig, P. (2003). *Artificial intelligence : A modern approach* prentice-hall. Site : <http://aima.cs.berkeley.edu>. 24

-
- [Sabouret and Sansonnet, 2001] Sabouret, N. and Sansonnet, J. (2001). Extraction de comportements à partir des interactions locales. *JFIADSMA'01*. 51, 83
- [Saria and Mahadevan, 2004] Saria, S. and Mahadevan, S. (2004). Probabilistic plan recognition in multiagent systems. In *Proceedings of International Conference on AI and Planning Systems*. 62, 69
- [Shapley, 1953] Shapley, L. S. (1953). Stochastic games. *Proceedings of the National Academy of Sciences of the United States of America*, 39(10) :1095. 46
- [Shi et al., 2004] Shi, Y., Huang, Y., Minnen, D., Bobick, A., and Essa, I. (2004). Propagation networks for recognition of partially ordered sequential action. In *Computer Vision and Pattern Recognition, 2004. CVPR 2004. Proceedings of the 2004 IEEE Computer Society Conference on*, volume 2, pages II-862. IEEE. 54
- [Shiwakoti et al., 2009] Shiwakoti, N., Sarvi, M., Rose, G., and Burd, M. (2009). Enhancing the safety of pedestrians during emergency egress. *Transportation Research Record : Journal of the Transportation Research Board*, 2137(1) :31-37. 118
- [Smelser, 1962] Smelser, N. J. (1962). *Theory of Collective Behavior*. 17
- [Steinberg and Bowman, 2004] Steinberg, A. N. and Bowman, C. L. (2004). Rethinking the jdl data fusion levels. *NSSDF JHAPL*. 38, 39
- [Steinberg et al., 1999] Steinberg, A. N., Bowman, C. L., and White, F. E. (1999). Revisions to the jdl data fusion model. In *AeroSense'99*, pages 430-441. International Society for Optics and Photonics. 38
- [Sukthankar, 2007] Sukthankar, G. (2007). *Activity recognition for agent teams*. PhD thesis, Citeseer. 45
- [Sukthankar and Sycara, 2005a] Sukthankar, G. and Sycara, K. (2005a). Automatic recognition of human team behaviors. In *Proceedings of Modeling Others from Observations, Workshop at the International Joint Conference on Artificial Intelligence (IJCAI)*. 47
- [Sukthankar and Sycara, 2005b] Sukthankar, G. and Sycara, K. (2005b). Identifying physical team behaviors from spatial relationships. In *Proceedings of Behavior Representation in Modeling and Simulation Conference (BRIMS)*. Citeseer. 33
- [Sukthankar and Sycara, 2006] Sukthankar, G. and Sycara, K. (2006). Simultaneous team assignment and behavior recognition from spatio-temporal agent traces. In *Proceedings of the National Conference on Artificial Intelligence*, volume 21, page 716. Menlo Park, CA ; Cambridge, MA ; London ; AAAI Press ; MIT Press ; 1999. 46
- [Sukthankar and Sycara, 2007] Sukthankar, G. and Sycara, K. (2007). Efficient plan recognition for dynamic multi-agent teams. In *Grace Hopper Women in Computer Science Conference*, pages 204-208, Orlando, FL. 46
- [Sumpter, 2006] Sumpter, D. (2006). The principles of collective animal behaviour. *Philosophical Transactions of the Royal Society B : Biological Sciences*, 361(1465) :5. 14
- [Tavcar et al., 2012] Tavcar, A., Gams, M., Kvassay, M., Laclavik, M., Hluchy, L., Schneider, B., and Bracker, H. (2012). Graph-based analysis of data from human behaviour simulations. In *Applied Machine Intelligence and Informatics (SAMII), 2012 IEEE 10th International Symposium on*, pages 421-426. IEEE. 169
- [Tran et al., 2005] Tran, D., Phung, D., Bui, H., and Venkatesh, S. (2005). Factored state-abstract hidden markov models for activity recognition using pervasive multi-modal sensors. In *Intelligent Sensors*,

Sensor Networks and Information Processing Conference, 2005. Proceedings of the 2005 International Conference on, pages 331–336. IEEE. 61, 70

[Turner and Killian, 1957] Turner, R. and Killian, L. (1957). *Collective behavior*. 15

[Tzu, 1997] Tzu, S. (1997). *L'art de la guerre*. Fayard/Mille et une nuits. 33

[Vail et al., 2007] Vail, D., Veloso, M., and Lafferty, J. (2007). Conditional random fields for activity recognition. In *Proceedings of the 6th international joint conference on Autonomous agents and multiagent systems*, pages 1–8. ACM. 54

[Van Ginneken and Van Ginneken, 2003] Van Ginneken, J. and Van Ginneken, J. (2003). *Collective behavior and public opinion*. Lawrence Erlbaum. 23

[Wada and Matsuyama, 1998] Wada, T. and Matsuyama, T. (1998). Appearance based behavior recognition by event driven selective attention. In *Computer Vision and Pattern Recognition, 1998. Proceedings. 1998 IEEE Computer Society Conference on*, pages 759–764. IEEE. 54, 57

[Wooldridge, 2002] Wooldridge, M. (2002). *An introduction to multiagent systems*. West Sussex, England : John Wiley and Sons Ltd, 348. 24

[Zacharias et al., 2008] Zacharias, G., MacMillan, J., and Van Hamel, S. (2008). *Behavioral Modeling and Simulation : From individuals to societies*. National Research Council of the National Academies Press. 23, 25

Cinquième partie

Annexes

"There is no such thing as an idea is well or badly understood.
Ideas was just well or badly explained."

Jérémy Patrix

Chapitre 9

Le projet EUSAS

Dans cette annexe, nous présentons le système développé dans le cadre du projet **EUSAS (Simulation Urbaine Européenne pour les Scénarios Asymétriques, *European Urban Simulation for Asymmetric Scenarios*)**. Par l'intermédiaire de ce projet, nous avons participé à la conception d'un simulateur hautement réaliste d'une foule ayant une culture et un environnement en fonction des scénarios de type asymétrique. Ce projet a été l'initiateur et le moteur des deux premières années de cette thèse.

Le système EUSAS a pour objectif l'entraînement et la préparation des forces pour les tâches de gestion des foules et des émeutes dans un contexte d'opération urbaine. L'entraînement d'une réelle patrouille, comportant un chef de section et trois soldats, a été effectué sur deux scénarios asymétriques distincts. Nous avons ainsi pu observer que le système connecte ensemble deux choses essentielles : un support pour la planification et l'analyse afin de développer et adapter la description standard : {*who, what, when, where, how, why*} pour l'entraînement à la gestion des foules et au contrôle des émeutes sur des scénarios asymétriques spécifiques.

9.1 Historique

Ce projet européen *Force Protection Call 4* (contrat A-0938-RT-GC) a été financé par 20 nations sous le **JIP FP (Joint Investment Program Force Protection²⁶)** de l'**EDA (European Defence Agency)** sur l'appel du "*Mission Planning/Training in an asymmetric environment*" and "*Secured Tactical Wireless Communications*" (A-0676-RT-GC). Ayant débuté en mars 2010, il a duré 30 mois et a impliqué un consortium de 6 partenaires européens : EDA, CASSIDIAN (an EADS company de France et d'Allemagne), JSI (*Jozef Stefan Institute* de Slovénie), FOI (de Suède) et CYFRONET (de Pologne).

Selon la proposition du projet : "*L'objectif de ce projet est de développer, démontrer et délivrer une nouvelle approche pour l'analyse de mission et l'entraînement d'unités bas niveaux face à des menaces asymétriques dans un environnement urbain*. Il aborde le sujet de la "modélisation du comportement humain" et "*aborde le besoin d'améliorer les capacités d'analyse et d'affiner l'entraînement de soldats par un cyber-environnement d'un haut niveau de réalité*."

26. i.e. le "Programme d'Investissement conJoint concernant la R&T sur la Protection des Forces", A-0120-RT-GC

En outre, les objectifs principaux suivants ont été abordés, jusqu'au niveau 4 ($\in [1, 9]$) du TRL (*Technological Readiness Level*²⁷) :

- L'analyse de mission et des capacités d'entraînement dans un environnement virtuel avec un haut niveau de fidélité (en prenant en compte les aspects physiques, émotionnels, sociaux, culturels, environnementaux) et une large variété de comportements modélisés,
- L'apprentissage automatique pour soulager la numérisation de nouveaux modèles de comportements humains dans les applications et l'adaptation des modèles existants,
- L'évaluation et l'optimisation des règles d'engagement et de procédures militaires,
- La vérification, la validation et l'accréditation (VV&A) du potentiel des modèles de comportements humains par l'évaluation qualitative et quantitative.

En bref, ses objectifs ont été atteints par les points clés suivants :

- La conception d'un modèle de comportement humain réaliste incluant des aspects tels que la prise d'information, l'état de l'agent, les motifs de comportements et les modérateurs de comportements,
- Le développement d'un système multi-agents pour les scénarios de menaces asymétriques,
- L'intégration d'un *serious game* (jeu sérieux) commercial pour l'entraînement de soldat et le clonage de comportements,
- Le développement d'un nouvel algorithme de clonage des comportements permettant la numérisation de comportements humains à partir des *logs* (enregistrements) du serious game,
- Le développement d'une infrastructure avancée de *Data Farming* permettant une analyse à large spectre des combinaisons des paramètres déterminant les aspects variables des règles d'engagement et du comportement de foule.

9.2 Implémentations

Dans cette section, nous allons présenter les composants du système EUSAS et notre contribution. Cette dernière nous a permis de maîtriser le serious game VBS2²⁸ [Australia, 2008], tels que le développement et l'intégration d'un plugin pour logger et contrôler, en temps réel, les agents et les événements afin de tester nos approches de détection.

Le schéma 9.1 représente les quatre composants principaux du système EUSAS avec leurs interactions :

▷ **ABS** (*Agent-Based Simulator*) [Hluchy et al., 2011, Kvassay et al., 2011, Laclavík et al., 2012, Kvassay et al., 2012, Hluchý et al., 2012, Kvassay et al., 2013] : estime le comportement des agents (i.e. Figure 9.2) en fonction de leurs perceptions de l'environnement, de leurs plans d'actions / objectifs internes / états internes (i.e. agressivité, peur, ...), de leur possibilité d'interagir avec l'environnement et de leurs motifs de comportements associés. ABS est basé sur le modèle de référence MPECS (*Military Physis, Emotion, Cognition, and Social status*). Au niveau logiciel, ABS utilise MASON une plateforme de simulation (écrit en langage Java) pour manipuler et coordonner les actions d'agents.

▷ **SG** (*Serious Game component*) : utilise le *serious game* VBS2 manipulé par des soldats jouant leur propre rôle. Il communique de manière bidirectionnelle avec ABS, pour interpréter ses ordres et lui

27. *Technological Readiness Level* : i.e. ISO 16290 la Définition des Niveaux de Maturité de la Technologie (NMT) et de leurs critères d'évaluation

28. Bohemia Interactive Simulations, Australia, 2011, <http://vbs2.com>





FIGURE 9.1 – Les composants principaux du système EUSAS

rendre compte de la situation. Étant le composant que nous avons développé, la section suivante décrit SG plus amplement.

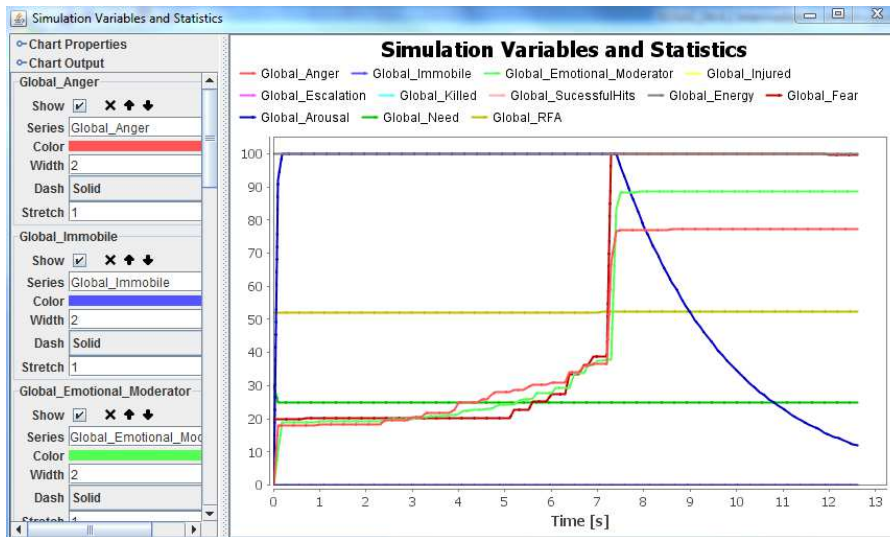
▷ DF (*Data Farming component*) [Krol et al., 2012, Kryza et al., 2012] : simule (sur des serveurs) un ensemble de (milliers) d'itérations de différents scénarios (de SG) avec divers paramètres initiaux. Chaque itération inclut de sensibles différences parmi les paramètres initiaux. Son site internet met à disposition une interface graphique pour choisir les paramètres (initiaux et des itérations), pour récupérer les logs des scénarios et pour obtenir des résultats statistiques des simulations.

▷ BC (*Behaviour Cloning component*) [Tavcar et al., 2012] : clone les stratégies des agents (en analysant les logs de SG de manière qualitative et de DF de manière quantitative) afin d'extraire les meilleures règles d'engagement pour les soldats. Ici, le terme "stratégie" signifie les séquences d'actions cognitives et physiques (intentionnelles) des agents. Pour le clonage, BC s'appuie essentiellement sur l'algorithme CMASDA (*Cognitive Multi-Agent Strategy Discovering Algorithm*, une extension de MASDA développée pour BC) et sur des ontologies décrivant les agents, leurs états, leurs actions, l'environnement et les événements possibles. Les stratégies sont résumées dans un AAG (*Abstract Action Graph*) par un processus *bottom-up* (i.e. Figure 9.3). En augmentant le niveau du AAG, les règles sont fusionnées par agrégation des plus proches, tout en gardant les plus rares selon la mesure des MoE préchoisies (*Measures of Effectiveness*, i.e. des mesures d'efficacité). Nous pouvons mesurer visuellement cette sélection en comparant les illustrations de l'interface graphique de BC en faisant passer l'AAG du niveau 0 à 6 (9.3(a) et 9.3(b)).

→ Les modèles de comportements d'ABS sont mis à jour par les résultats de BC (analysant les logs de DF et SG) afin de réopérer une nouvelle boucle du système EUSAS.

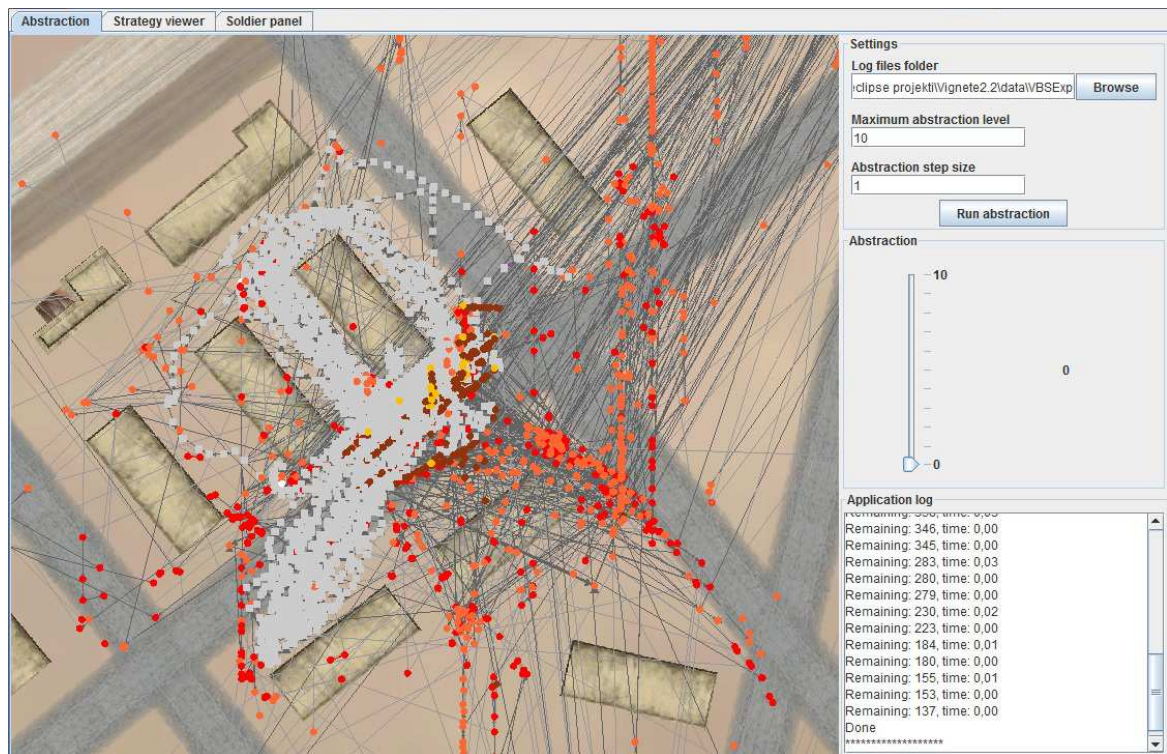



(a) Vue 2D d'une situation asymétrique : un groupe d'agents civils (simulés en marron) sont en train de communiquer avec une patrouille de soldats (joués en cyan) devant l'entrée d'une base militaire. Un civil lance une menace verbale (affiché par "threaten_event") à un soldat et un soldat de la tour de guet répond par le chargement de son arme ("load_gun_event").




(b) Vue statistique des variables internes moyennes des agents civils : la colère et la peur montée à 75% et 100% (lignes rouges) ont produit l'événement de menace du civil.

FIGURE 9.2 – Interface graphique de la plateforme ABS (Agent-Based Simulator)

(a) Vue d'un AAG (*Abstract Action Graph*) produisant un modèle macro à partir des séquences d'actions micro.

(b) Vue d'un AAG produisant un modèle macro au niveau 6 d'abstraction.

FIGURE 9.3 – Interface graphique de la plateforme BC (*Behaviour Cloning component*)



(a) Vue 2D de la ville produite dans VBS2 : une base militaire entourée d'un environnement urbain (du sud-ouest asiatique) de 900m x 600m.



(b) Vue 3D à la 3ème personne de VBS2 incluant des ajouts personnels : une liste des actions disponibles pour communiquer et agir, un message de réponse par un civil, l'état de chaque agent par une émoticône colorée au-dessus de sa tête.

FIGURE 9.4 – Vue 2D/3D de VBS2 (intégré dans le composant SG).

9.2.1 SG - Serious Game component

Nous avons développé ce composant SG. Il est constitué de deux parties : la première est l'interface utilisateur de VBS2 et la seconde est un système pour la communication bidirectionnelle entre VBS2 et un composant externe.

Il est à prendre en compte que les informations suivantes ne sont pas intégrées facilement par défaut dans VBS2. Pour ce faire, il a fallu apprendre le langage unique de VBS2 appelé SQF, un langage séquentiel interprété. VBS2 est une *blackbox* et ne possède pas d'interface *debug* avancée (i.e. il est rare d'avoir un message d'erreur décrivant le bug qui s'est produit, à la place il se produit souvent une fermeture intempestive du programme).

A. Interface utilisateur de VBS2

En nous basant sur une carte 2D qui nous a été fournie (Figure 9.4(a)), nous avons produit une carte incluant une ville 3D où se déroulent nos différents scénarios asymétriques. Un aperçu est disponible dans l'illustration 9.4(b) : des routes, des bâtiments, des agents ont été choisis selon cet environnement spécifique (*du sud-ouest asiatique*).

VBS2 est un *serious game*, il n'y a donc aucune information affichée que le joueur n'est pas sensé observer dans la réalité (telle que les états émotionnels des autres agents). Nous avons alors ajouté plusieurs fonctionnalités correspondant aux scénarios :

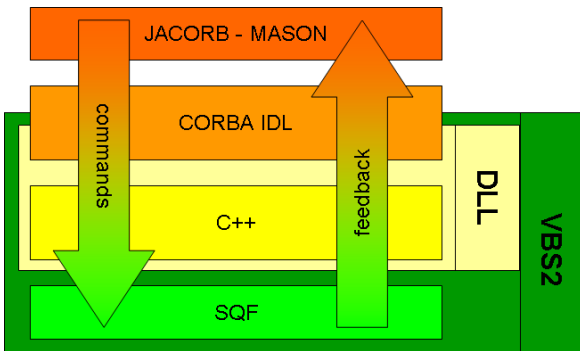
- ◇ Deux lignes d'informations sont au-dessus de chaque personnage : la 1^{ère} est la motivation principale interne de l'agent, la 2nd est la motivation déclencheuse de l'action de l'agent. Les deux fournissent une couleur selon l'émotion prépondérante. Le tableau 9.5(a) les résume. Avant, le joueur avait une difficulté pour savoir si l'agent, avec qui il converse, est dans un état émotionnel normal, effrayé ou en colère. Les animations du visage sont facilement mises à jour, mais le soldat doit être trop proche pour pouvoir lire attentivement le visage. Dans la capture d'écran 9.4(b), vous pouvez apercevoir une croix rouge au-dessus de l'agent civil à droite, il signifie une absence d'action, mais aussi un état interne en colère. Le personnage devant au centre (vue à la 3^{ème} personne) est le soldat qui joue. Au-dessus de lui, il y a un smiley qui représente l'action d'interrogation. Pour cette raison, un civil à gauche répond qu'il n'a pas d'objet (puisque le scénario est l'intervention d'une patrouille face à une foule en train de piller un magasin).

- ◇ Plusieurs modes de communications et d'actions (produisant les animations de VBS2 les plus proches) sont ajoutés à l'interface (en bas à droite dans la capture d'écran 9.4(b)). Le joueur choisit, active et interrompt l'action qu'il veut quand il le veut. Il est à savoir que chacune d'elles est considérée comme un événement loggé et envoyé à ABS en temps réel, de manière à ce que les civils y réagissent. Le tableau 9.5(a) présente les réponses qu'un soldat devrait choisir en fonction des actions des civils et inclut les émoticônes correspondantes. Par défaut, VBS2 comporte toutes les actions possibles pour manipuler les objets qu'ils portent (armes, lunettes, munitions, radios,...) et certains de l'environnement (véhicules, portes,...). Toutefois, il n'y avait aucune action pour communiquer malgré les dizaines d'animations "en train de communiquer" intégrées dans VBS2.


émoticones	Actions des civils	Réponses des soldats	émoticones
(o_o)	Négocier (par un leader civil)	Communiquer calmement	(o_o)
(-_-)	Provoquer calmement	Communiquer avec attention	(O_o)
('_')	Provoquer agressivement	Gesticuler	(~_~)
(>_<)	Menacer	Prendre son arme en main	('_')
\('_')/	Attaquer sans arme	Charger son arme	(>_<)
\(>_<)/	Jeter des pierres	Coup de semonce en l'air	\('_')/
\(>_<)/	Répéter le jet de pierres	Coup de feu dans les jambes	\(>_<)/
Un texte	Répondre	Interroger	(e_e)
		Utiliser le mégaphone	(0o0)

	Motivation principale (1 ^{ère} ligne)	Motivation déclenchée (2 nd line)
Colère	Rouge	X
Peur	Bleu	O
Cherche/à attaqué	Jaune	N
En train de ramasser	Vert	
Rien	Blanc	-

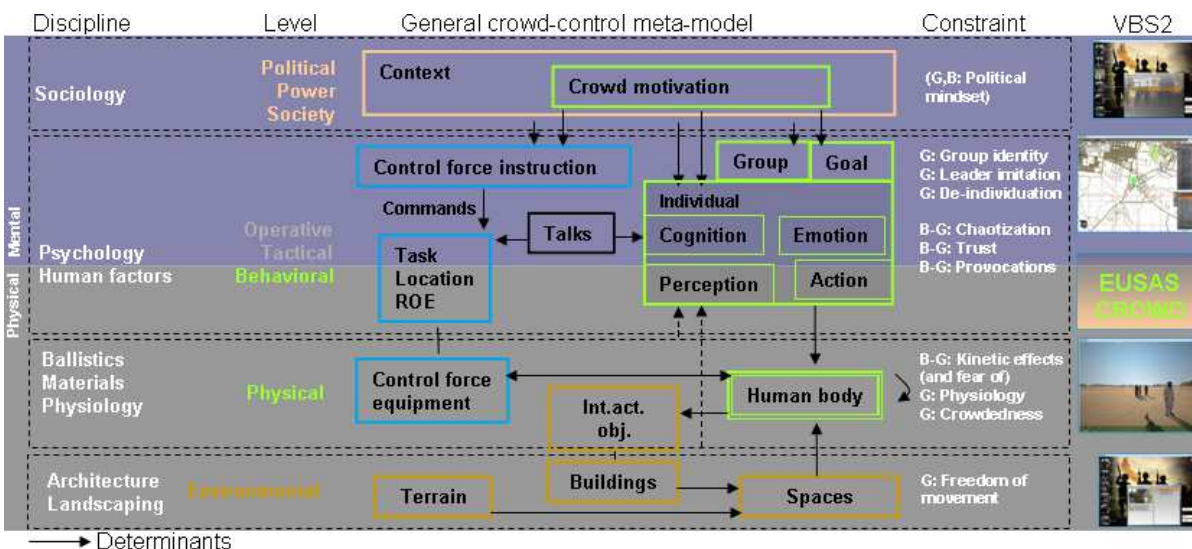
(a) Émoticones des actions communicatives et couleurs des émotions des agents soldats et civils.



(b) Communication bidirectionnelle entre VBS2 (le serious game de SG) et MASON (la plateforme d'ABS).



(c) Matériel EUSAS utilisant le serious game en réseau avec plusieurs joueurs.



(d) Niveaux du modèle d'interactions sociologique des scénarios EUSAS.

FIGURE 9.5 – Implémentations dans le simulateur VBS2.

B. Communication bidirectionnelle en entrée/sortie de VBS2

Le schéma 9.5(b) résume la communication bidirectionnelle entre VBS2 (de SG) et MASON (d'ABS). Elle est permise par un plugin DLL que nous avons développé (en langage C++) et qui s'intègre dans VBS2. Ses caractéristiques sont les suivantes :

▷ Le plugin échange des informations en se connectant à un protocole de communication du type bus Corba (*Common Object Request Broker Architecture*). Corba est un standard d'architecture logicielle distribuée permettant la programmation orientée objet et la communication entre un ensemble de composants logiciels. Par exemple, différents types de composants sont codés sur différents langages et/ou opèrent sur différents ordinateurs, mais ils communiquent tous par le même protocole de communication et une interface commune. Notre interface commune est écrite en langage IDL (*Interface Description Language*) et comporte un ensemble de méthodes qui servent à commander les agents dans VBS2 et à informer de leurs états et des événements de VBS2.

▷ Pour ce qui est de la communication de VBS2 vers MASON, un fichier écrit en langage SQF (de notre conception) est automatiquement chargé lors d'un scénario. VBS2 l'interprète et envoie constamment au plugin deux types d'informations : (1) toute mise à jour des variables des agents (e.g. positions, vitesses, orientations, direction de la tête, munitions, positions du corps et de l'arme,...), et (2) tout événement (e.g. un tir d'arme, un jet de pierre, l'ouverture d'une porte, toutes actions des civils / soldats,...). Le plugin reçoit un objet *string* de VBS2, le décode, et exécute les méthodes en C++ qui correspondent à l'interface commune. À l'exécution d'une méthode, sa version IDL avec ses paramètres sont automatiquement envoyés par le protocole de communication Corba. Le composant MASON qui est connecté à ce bus Corba obtient l'information, l'interprète automatiquement dans son langage Java.

▷ Pour ce qui est de la communication de MASON vers VBS2, c'est inversé. Puisque MASON connaît la situation des agents et les événements, chaque agent décide de l'action à effectuer selon son modèle de comportement. Ces décisions sont interprétées par les méthodes de l'interface commune et envoyées sur le bus Corba. Le plugin les reçoit, les interprète en *string* SQF et les envoie à VBS2. Ce dernier les interprète en méthodes correspondantes du fichier SQF que nous avons développé (qui contrôle les agents). Ces méthodes de contrôles sont celles présentées dans la Figure 9.5(a).

Pour utiliser le serious game en réseau, il faut un ordinateur avec un bon processeur puisqu'il sert de "serveur" pour créer la partie et est manipulé par ABS en temps réel. Les autres ordinateurs pour les joueurs ne feront que s'y connecter et n'ont besoin que de la puissance de calcul graphique nécessaire au serious game.

9.3 Expérimentations

Lors de deux démonstrations en présence du consortium d'EUSAS (nos partenaires, l'EDA,...), deux scénarios asymétriques ont été testés par une équipe de quatre opérationnels de l'Armée Française. Deux scénarios ont été principalement utilisés : n° 1 "*Des civils mécontents devant une base militaire*" et n° 2 "*Une patrouille face au pillage d'un magasin*". Les comportements collectifs ont été vérifiés par des experts (sociologues) dont les caractéristiques sont (décrites dans le schéma 9.5(d) et) séparées en quatre niveaux d'observation distincts :

1. Sociologie : les motivations politiques de la foule.
2. Facteurs humains et psychologie : les comportements des soldats (tels que les tactiques de contrôle de la foule) et des civils (tels que l'identité du groupe, l'imitation de leur leader, la désindividualisation, les provocations, le chaos ambiant, les croyances,...) ;

3. Physiologie, équipements et balistiques : les animations des corps des soldats (notamment par rapport aux équipements militaires) et des civils (tels que le jet de pierres et les déplacements en groupe).

4. Architecture du paysage : la réalité de l'environnement (sud-ouest asiatique) et de ce qu'il inclue (bâtiments, routes, murs, base militaire,...).

9.3.1 Scénario asymétrique n° 1 - Civils mécontents devant une base militaire

Nous allons résumer le déroulement du scénario n° 1 (Illustration 9.6) :

- Deux groupes de civils viennent communiquer avec les soldats devant l'entrée de la base militaire par l'intermédiaire de leur leader respectif ;
- Chaque leader pense que l'autre groupe est avantagé. Les civils se mettent en colère si les soldats ne communiquent pas ou ne répondent pas à leurs attentes ;
- En fonction du niveau de communication de "calme à agressif" et des actions des civils, les soldats doivent choisir l'action qui y correspond, sinon les civils peuvent se mettre en colère ou s'enfuir effrayer puis revenir en colère, lancer des pierres et attaquer avec des bâtons.
- Le scénario se termine par une réussite avec la foule partant dans le calme, ou par une défaite avec la foule en colère obligeant les soldats à venir se protéger dans la base militaire.

Ce scénario a été produit une quinzaine de fois avec deux paramètres initiaux possibles : soit les civils étaient calmes, soit ils étaient déjà en colère.


Les soldats n'avaient jamais utilisé cette simulation ou rencontré ce scénario. Cela leur a requis une quinzaine d'itérations (en 1h) pour apprendre comment gérer la foule par la communication et calmer la situation quand il y a des violences. Les soldats étaient libres de leurs actions et ne faisaient qu'un rapport de leurs actes et de leurs observations à leur leader présent derrière les écrans. Ils ont donc testé les différentes actions par rapport aux comportements collectifs. Ils ont vite compris qu'exécuter une action trop agressive (par rapport à la situation) stoppait temporairement les civils en les faisant s'enfuir, pour mieux revenir avec des comportements violents et ingérables, obligeant les soldats à rentrer dans la base. La première difficulté pour les soldats a été de comprendre les animations (tels que les signaux des mains pour demander de s'approcher ou de s'éloigner). En effet, celles choisies correspondent à la culture des civils et non pas à celle des soldats. Cela a eu pour effet de les habituer rapidement à reconnaître leurs comportements sans en connaître la langue.

9.3.2 Scénario asymétrique n° 2 - Patrouille face au pillage d'un magasin

Nous allons résumer le scénario n° 2 (Illustration 9.7) :

- Un peloton de soldats patrouille dans la ville et s'aperçoit qu'un pillage est en train de se produire. Lorsque les soldats les approchent pour stopper le pillage, les civils partent avec leur butin.
- Les soldats utilisent le mégaphone pour leur demander de déposer à terre ce qu'ils ont volé et de partir. Des civils sont interrogés pour évaluer la situation. D'autres sont mécontents et jettent des pierres. Les soldats doivent alors protéger le magasin et interroger les civils pour les dissuader de revenir continuellement.

Tout comme le scénario n° 1, l'agressivité des communications et des actions des civils augmente lors de mauvaises réactions des soldats. Dans le cas contraire, la situation se calme.




(a) Localisation du scénario n° 1 : devant l'entrée d'une base militaire (en marron), il y a (en bleu) un périmètre de sécurité pour les soldats et (en jaune) pour les civils.



(b) Quatre vues durant le scénario au même instant : trois vues 3D des joueurs soldats par VBS2 et une vue 2D de la situation par MASON.

FIGURE 9.6 – Scénario asymétrique n° 1 dans VBS2.



(a) Localisation du scénario n° 2 : à la vue d'un magasin en train de se faire piller par une foule de civils.



(b) Trois vues 3D durant le scénario au même instant par des joueurs soldats dans VBS2.

FIGURE 9.7 – Scénario asymétrique n° 2 dans VBS2.

L'expérience du scénario n° 1 a facilité l'apprentissage la gestion de foule. Toutefois, une douzaine d'itérations (1h) du scénario n° 2 a été requise. En effet, l'aspect coopératif entre les soldats était plus important dans ce scénario, pour que chacun protège les angles morts des autres soldats du peloton en surveillant la foule et le magasin, communiquant avec le leader sur leurs observations de la situation, sachant qu'ils n'avaient pas de zones où se protéger en cas d'actes agressifs de la foule.

9.4 Conclusion

Beaucoup de perspectives ont été produites suite à ces démonstrations. Ce n'est pas un produit, mais une preuve de concept à propos de deux choses. Le système d'analyse produit de nouvelles règles d'engagement afin d'améliorer la communication et les actions entre les soldats et les civils. Des soldats inexpérimentés pourraient rapidement apprendre les comportements collectifs d'une foule dans un lieu où la culture et les normes ne sont pas celles des soldats. Cela éviterait des erreurs de débutant, moins de temps en entraînement réel (puisque les soldats auraient directement les bons comportements), et notamment un coût moindre (en quantité d'équipements et de temps d'entraînement). Excepté le coût de la conception de chaque scénario sur lequel s'entraîner, une simulation peut être reproduite à l'infini sans coût supplémentaire.

Dans le cadre de la thèse, l'expérience de ces scénarios a été d'une grande aide afin de savoir comment simuler des comportements collectifs sociaux et culturels en fonction de l'environnement. L'implémentation d'un tel système nous a permis de savoir comment utiliser VBS2 afin de logger les états et les événements produits afin de tester nos approches de détection. Bon nombre d'erreurs de débutant ont ainsi été évitées en s'appuyant sur l'expérience de nos partenaires qui ont produit les composants du simulateur de modèle humain (ABS) et de clonage du comportement humain (CMASDA).

Nous aurions pu tenter d'utiliser les modèles de comportements résultant du processus de clonage (par l'algorithme CMASDA du composant BC) afin de les détecter en temps réel. Des résultats de détection sans doute satisfaisants auraient été produits. Néanmoins, la détection n'aurait été fonctionnelle que spécifiquement pour ces deux scénarios, puisque fortement liée à ces deux environnements et aux actions possibles de ces types précis d'agents. Toutefois, l'utilisation d'**ontologies qui décrivent les interactions possibles entre un agent et un objectif** possible pourrait affiner les modèles présentés dans ce manuscrit. Par exemple, la détection des comportements objectivés pourrait éviter de calculer les comportements et les intentions "sans risque" en fonction des types de groupes et d'objectifs, et se concentrer sur ceux plus spécifiques de la situation (afin de les anticiper au plus tôt).

Chapitre 10

Le projet DEM@CARE

Nous présentons dans cette annexe le système développé dans le cadre du projet **DEM@CARE** (*Dementia Ambient Care : Multi-sensing Monitoring for Intelligent Remote Management and Decision Support*). L'objectif du projet Dem@care est de développer un système personnel de santé ciblant les troubles liés à la démence. Il s'agit d'obtenir des indicateurs sur la condition et la progression de la maladie de la personne. Le système s'appuie sur la fusion et l'analyse d'une multitude de capteurs pour le suivi multi-paramètres des activités de la vie quotidienne, du comportement et de santé. Ces processus (i.e. Figure 10.1) fournissent de nouveaux outils pour un meilleur suivi par les personnels soignants et médicaux, afin de faciliter le maintien d'un bon niveau de qualité de vie et d'autonomie (i.e. d'indépendance). **Ce projet a été le moteur de la troisième année de cette thèse.**



FIGURE 10.1 – Processus général du projet DEM@CARE

Dans Dem@care, les personnes atteintes de démence seront surveillées par différents capteurs dans leurs tâches de la vie quotidienne (comme la cuisine ou regarder la télévision), leurs activités cognitives et leurs interactions sociales. Au premier stade, cela aura lieu dans des environnements contrôlés (i.e. le milieu hospitalier) et par la suite, dans leurs maisons. Ces observations seront analysées et interprétées automatiquement pour permettre la corrélation des comportements spécifiques à la progression de la maladie et ainsi des retours personnalisés. Par exemple, la détection de l'apathie à long terme peut contribuer à la compréhension de la façon dont la maladie affecte la vie et le comportement au jour le jour et, en même temps, fournir de la rétroaction et de la stimulation vers un mode de vie plus actif.

En premier lieu, nous allons présenter ce projet, puis le système DEM@CARE et notamment notre **contribution** que nous pouvons résumer par : l'aide au développement, l'intégration et la communication de tous les composants développés par nos partenaires (des capteurs de surveillance, de l'analyse de leurs données et des interfaces graphiques utilisateurs), puis de l'ajout de notre composant de fusion des observations par du CEP (traitement d'événement complexe, i.e. section 2.2.3).

10.1 Introduction

La recherche menant à ces résultats a reçu un financement au titre du *European Community's Seventh Framework Programme* (FP7/2007-2013) sous la convention de subvention 288199. Ce projet sous l'identifiant FP7-ICT-2011-7-288199 a débuté en novembre 2011 et se termine en novembre 2015. La fiche d'information (*factsheet*) de ce projet européen FP7 est accessible à l'URL du site²⁹. Une douzaine de partenaires coopère au développement du projet : **Cassidian** (EADS, France), CERTH (*Centre for Research and Technology Hellas*, Grèce), UB1 (*Université de Bordeaux I*, France), INRIA (*Institut National de Recherche en Informatique et en Automatique*, France), LTU (*Luleå Tekniska Universitet*, Suède), DCU (*Dublin City University*, Irlande), IBM (*Israel – Science and Technology LTD*, Israël), Philips (*Electronics Nederland B.V.*, Pays-Bas), CHU de Nice (France), Vistek (*Isra Vision Yapay Görme ve Otomasyon Sanayi ve Ticaret Anonim Sirketi*, Turquie) et Link Care Services SA (France).

10.1.1 Contexte clinique

La démence (*dementia*) (incluant la maladie d'*Alzheimer*) est une cause principale d'invalidité chez les personnes âgées et touche actuellement près de 10 millions de personnes en Europe et plus de 35 millions dans le monde. Ces chiffres devraient augmenter respectivement à 14 et 65,7 millions en 2030. Les répercussions socio-économiques sont tout aussi stupéfiantes. Rien qu'en Europe, le coût total du montant de la démence est à plus de 180 milliards d'euros en 2010 et sont estimé à plus de 250 milliards d'euros d'ici 2030. Cela infligera un lourd fardeau sur les systèmes de santé, la société et l'économie, et nécessite des moyens de traitement efficace, tout en préservant la qualité de vie des personnes touchées et de leurs soignants (i.e. les personnes qui s'en occupe, telles que les proches familiaux et les auxiliaires de vie).

29. Site Dem@care : <http://www.demcare.eu>

10.1.2 Objectif

Les pratiques cliniques actuelles pour la démence impliquent une évaluation gériatrique par les cliniciens à travers des visites et des questionnaires, où le diagnostic est basé sur l'évolution des fonctions cognitives, des comportements / des activités de la vie quotidienne, des caractéristiques du syndrome de démence et des maladies sous-jacentes. Dem@care s'attend à améliorer ces pratiques cliniques actuelles et à permettre de nouvelles connaissances reliées au diagnostic et au traitement de la démence. Plus précisément, Dem@care est anticipé pour produire :

- Des protocoles cliniques corrélés de manière efficace aux entrées sensorielles reliées aux tendances comportementales et cognitives avec les paramètres spécifiques de la démence.
- L'explicitation et la validation de nouvelles connaissances cliniques pour améliorer la précision du diagnostic et son efficacité.

Ces résultats permettront à Dem@care d'avoir un fort impact sur la qualité de vie des personnes atteintes de démence, avec des effets directs sur leurs soignants informels ainsi, en fournissant :

- (1) Une amélioration de la qualité des soins, à travers l'objectif du diagnostic complet et personnalisé d'un support réactif et proactif.
- (2) Une augmentation de la sécurité des données personnelles et du sentiment de sécurité dans les lieux surveillés, grâce à la rétroaction adaptative en temps réel et des alarmes.
- (3) Le traitement en temps opportun des symptômes de la maladie, offerte par la détection précoce de la dégradation de l'état de santé et par le soutien cognitif personnalisé.
- (4) L'indépendance et l'autonomie prolongées, permettant de mieux faire face aux fonctions de la vie quotidienne, tout en réduisant la nécessité d'une surveillance constante.

En parallèle, Dem@care s'attend à ce qu'il y ait des avantages socio-économiques importants, notamment une réduction du coût des soins cliniques et de surveillance, l'admission différée aux installations de soins infirmiers, et des solutions durables de soins à domicile.

10.2 Système Dem@care

Le système sera déployé dans trois environnements différents exigeant un ensemble commun d'exigences ainsi que certaines exclusives :

▷ À la maison, le système permettra de suivre et de mesurer l'activité du patient et d'enregistrer les paramètres de la vie quotidienne pour l'évaluation clinique ultérieure. Il déclenche des alarmes dans les situations d'urgence, et fournit également une rétroaction et des conseils pour le patient si nécessaire. Le soignant va également bénéficier de fonctionnalités Dem@care en aidant le patient dans ses activités quotidiennes. Le clinicien aura accès aux données de haut niveau du patient créées et inférées par le système de Dem@care à partir des données brutes des capteurs.

▷ À la maison de retraite, les fonctionnalités du système (sont similaires à ce qui précède et) permettront d'interagir avec plusieurs soignants. Ces derniers bénéficieront du système pour faire face à plusieurs patients en même temps.

▷ Au laboratoire, les patients seront impliqués dans les tests d'activités mentales et physiques afin d'obtenir un bref aperçu de leur état de santé (i.e. les fonctions cognitives et les comportements) lors de la consultation. Les données du système Dem@care seront corrélées avec les outils d'évaluation typiques.

La validation et l'évaluation de la technologie Dem@care sont un aspect important du projet. Un processus d'évaluation en trois étapes a été défini afin d'assurer la saillance et l'efficacité des systèmes développés. Plus précisément, pour les versions suivantes du prototype Dem@care auront une phase d'évaluation pour :

- v1.0 : vérifier la facilité d'utilisation, sa fonctionnalité et sa fiabilité, et d'en affiner les besoins fonctionnels ;
- v2.0 : se concentrer principalement sur les qualités extérieures de Dem@care par une évaluation informative, entre autres, de l'adéquation, l'exactitude, la sécurité, la maturité,...
- v3.0 : évaluer l'efficacité et l'impact global du système de Dem@care, y compris les considérations cliniques (cognitives, comportementales,...), les facteurs liés à l'amélioration de la qualité de vie des personnes atteintes de démence et leurs proches,...

10.2.1 Composants et leurs niveaux

La Figure 10.2 résume les communications entre les différents composants du 1^{er} prototype du système Dem@care. Il est inclus :

- Les composants de **bas niveau** qui communiquent avec leurs propres capteurs et analysent leurs données :

- ★ HAR (*human action recognition*) reconnaît des actions humaines et des interactions (humain / humain et humain / objet) produites par le PwD sur les données vidéos issues d'une caméra *Kinect*. En exemple les actions reconnues sont : être debout ou assis, manger une banane, décrocher le téléphone.

- ★ OSA (*offline speech analysis*) estime (après l'enregistrement par un microphone de) l'état cognitif et l'humeur du PwD en analysant le son audio (i.e. la voie).

- ★ DTI-2SW fournit une analyse métrique de la stabilité de la marche et des activités physiques en se basant sur les accéléromètres contenus dans une montre portée par le PwD.

- ★ RRWC / ORWC (*wearable camera*) détecte la pièce et les objets interagissant avec le PwD en analysant les données vidéo issues d'une caméra *GoPro* portée par le PwD.

- ★ Gear4 mesure la qualité du sommeil en se basant sur le rayonnement électromagnétique des mouvements capté par le *Renew Sleep Clock* (i.e. un réveil sophistiqué, connecté à un iPhone utilisant son application).

- ★ WIMU : utilise des algorithmes de traitement du signal (issues des accéléromètres et magnétomètres) afin de détecter des activités telles que l'orientation, la position et la posture du PwD.

- ★ SenseCam : est non-développée pour cette version du prototype, mais le sera.

- Les composants de **haut niveau** qui produisent les inférences :

- ★ SI (*semantic interpretation*) : reconnait les activités / événements de haut niveau associés au comportement du PwD (notamment les problèmes / anormalités), par une analyse sémantique des observations en utilisant des règles et des ontologies, afin de produire un rapport d'activité quotidienne ;

- ★ CAR et PDT-PER (*complex activity recognition*) infère sur les activités complexes (i.e. événements) de la vie quotidienne du PwD en se basant sur les observations d'une caméra *Axis* ;

- ★ KBM (*knowledge base manager*) est la base de connaissances qui stocke toutes les données d'observations au format RDF pour de futures analyses ;




FIGURE 10.2 – Services web du 1^{er} prototype du système Dem@care

★ GUI : inclus les interfaces utilisateurs, qui selon le profil de l'utilisateur, permettent d'administrer le système, de lire les rapports d'activités quotidiennes, d'être alerté en temps réel, d'indiquer des informations aux PwD,... tout ceci en communiquant avec la base de connaissances.

○ **Controller** : est notre service web qui sert d'intermédiaire entre tous les composants (de bas et haut de niveaux). Pour cela, il (i) établit automatiquement et dynamiquement une communication avec tous les composants *web services*, (ii) récupère les observations issues des analyses (des composants bas niveaux), (iii) les fusionne et les analyse à son tour par *Complex Event Processing*, puis (iv) envoi le tout aux composants de haut niveau.

10.2.2 Intégration des composants en services web

L'architecture logicielle est en SOA (*service oriented architecture*). Cela permet d'éviter une quelconque dépendance entre les composants et la plateforme les intégrant. Chaque composant logiciel est développé indépendamment dans un service web. L'idée basique est que chaque web service consomme et produit des données définit dans un **modèle d'échange commun**. Par exemple, ce modèle décrit les objets "Observation" dans le langage XSD (*XML Schema Definition*) et décrit les interfaces des services web dans le langage WSDL (*Web Services Description Language*, une grammaire XML recommandée par W3C).

Le langage WSDL décrit une interface publique d'accès à un service web (notamment en SOA) :

- Le protocole de communication utilise des messages orientés SOAP (*Simple Object Access Protocol*, bâti sur du XML) et qui sont transférés à l'aide du protocole HTTP. Le protocole SOAP est composé de deux parties : une enveloppe (i.e. les informations permettant l'acheminement et le traitement du message) et un modèle de données (i.e. un format de message pour les informations à transmettre, ici en XSD).
- Les méthodes web que le client du service peut invoquer (e.g. la méthode "*getObservations*" est celle utilisée par notre "Controller" pour obtenir les observations des composants bas niveaux).
- La localisation du service (i.e. une url incluant une adresse ip et un numéro de port).

Les services web ont besoin d'une plateforme *open-source* pour être déployés. Pour cela, nous utilisons **Apache ServiceMix**³⁰ (sous licence Apache) qui offre un BUS de communication pour les services. De cette manière, différents composants, pouvant être codés en différents langages (majoritairement en Java, mais aussi en C++), présent sur différents systèmes d'exploitation (tels que Windows ou Linux, souvent en fonction des pilotes des capteurs), peuvent se communiquer des informations en local et en réseau.

L'architecture d'un projet java d'un service web est générée automatiquement avec le logiciel **Maven**³¹ (sous licence Apache), en se basant sur les interfaces décrites en WSDL et les objets décrits en XSD. Comme nous intégrons tous les composants des partenaires, notre travail a consisté à créer des projets vides de services web et un tutoriel leur indiquant comment ils sont générés et mis à jour automatiquement (en fonction du modèle d'échange de données et des interfaces communes), et comment l'implémenter de manière à ce que leurs composants puissent produire et communiquer ses résultats

30. Le site d'Apache ServiceMix : <http://servicemix.apache.org/>

31. Le site d'Apache Maven : <http://maven.apache.org/download.cgi>

d'analyses. Les partenaires y ont intégré leurs composants en *open-source* (i.e. ouvert) ou en *black-box* (i.e. fermé) lorsqu'il y a propriété intellectuelle sur le code source.

Notre processus d'intégration nous a permis d'avoir la version 1.0 d'un prototype du système Dem@care seulement après trois mois. Après six mois, sa version 1.5 est contenue sur une simple clé usb qui permet de l'installer et de l'utiliser en suivant notre tutoriel. Il est depuis testé réellement sur trois sites en Europe, dont deux laboratoires de recherche et un hôpital. Ce processus est dans le but de l'amener à sa version 2.0 en améliorant chacun des composants et son automatisation du transfert des informations allant des capteurs jusqu'aux interfaces graphiques.

10.2.3 Dans le FusionLab de notre équipe IPCC de Cassidian

Nous avons développé et intégrés les composants du système Dem@care dans le FusionLab, un produit de notre équipe IPCC (*Information Processing Control and Cognition*) du SDC (*System Design Center*) de **Cassidian** (an EADS company), auquel nous appartenons. La description du FusionLab ci-dessous a été produite dans [Bellenger et al., 2011, Bellenger, 2013].



"Le **FusionLab** (an *Information Fusion Semantic and Service Enablement Platform*) est un ensemble (**framework**) de composants et d'outils logiciels permettant de créer facilement par composition, **un système de fusion d'information**. Ces composants sont suffisamment génériques pour être étendus en fonction des besoins spécifiques à un domaine d'application particulier. Le FusionLab a en effet été développé dans un objectif de **capitalisation** de l'expertise technique et métier au sein de **Cassidian**. En découlent des possibilités de prototypage plus rapides : ainsi, une instanciation du FusionLab est une implémentation particulière (qui peut se résumer à une configuration particulière) des composants pour un besoin ou projet spécifique. Le FusionLab sert de plateforme de développement et d'intégration reposant sur un certain nombre d'outils open-source dédiés.

L'une des spécificités du FusionLab réside dans son modèle métier sous-jacent basé sur des **ontologies**. Cela permet ainsi une représentation sémantique de la connaissance et donc la possibilité d'utiliser des composants ayant des capacités de **raisonnement** tournées vers l'expressivité du modèle.

L'architecture FusionLab est basée sur une approche d'**architecture orientée service** (SOA). Pour ce faire, nous utilisons Apache ServiceMix (open source), qui permet notamment un bus de service en charge de la médiation entre les différents services. Concernant les services, ceux-ci sont regroupés en deux catégories : les services capitalisés et les services spécifiques.

Les services capitalisés définissent des opérations récurrentes pour divers domaines d'applications et sont donc utilisés dans différentes instanciations du FusionLab. La liste de ces services croît au fil des instanciations du FusionLab. Il s'agit en général des services de visualisation, de simulation, de technique de raisonnement, de gestion de la base de connaissances, ... Cependant la plupart de ces services restent à configurer de façon particulière lors d'une instanciation. C'est le cas notamment du service de **raisonnement à base de règles** (tel que les CEP) où les règles sont à définir pour chaque

application. Les services spécifiques sont ceux n'intervenant que dans une instanciation particulière du FusionLab et qui correspondent à un besoin très particulier que l'on ne souhaite pour le moment pas capitaliser.

Les services se basent sur des modèles d'interfaces types correspondant aux grandes catégories métiers de services. On retrouve ainsi des interfaces pour des services dédiés à **la détection d'anomalie, à l'identification d'objets, au tracking, ...** Concrètement, il s'agit d'un fichier écrit en langage standard WSDL 2.0 décrivant comment ce type de service communique. Ce langage permet notamment de définir le format des messages requis et les méthodes qui peuvent être invoquées, en séparant la déclaration abstraite de la définition concrète (comme le protocole utilisé). Le fichier contient les définitions des contrats des services écrits en langage XML. De plus, le schéma XML utilisé dans les contrats des services du FusionLab est limité à des concepts génériques et abstraits, dont un attribut spécifique qui contient le message concret fourni sous forme d'ontologie. Le message sous format ontologique est, pour des besoins techniques, encapsulé dans une enveloppe XML. En effet, le FusionLab repose avant tout sur une architecture où les services échangent et raisonnent sur de la connaissance modélisée sous forme d'ontologies.

En élément majeur de l'architecture, des bases de données ainsi que des bases de connaissance fournissent la capacité de persistance des informations manipulées ainsi que des informations a priori ou contextuelles auxquelles certains services auraient besoin d'accéder."

10.2.4 Analyse produite des activités quotidiennes

Après l'acquisition de données (i.e. leur collection, leur prétraitement et leur gestion), l'analyse se produit en quatre parties distinctes : la *mesure*, la *détection*, la *reconnaissance*, et la *connaissance sémantique*. Le résultat est alors présenté au PwD, aux soignants et aux cliniciens.

La *détection* déclenche un processus lors de l'observation d'un événement significatif dans les données de capteurs. C'est le plus bas niveau de l'analyse. La *mesure* génère des informations qui peuvent être extraites à partir des capteurs après que la *détection* a eu lieu. La *reconnaissance* concerne un comportement qui peut être reconnu à partir d'un ensemble de *détections* en plus de *mesures*, combinés avec la base de connaissances (i.e. des ontologies d'activités).

Les fonctions de *mesure* se rapportent à une *détection* d'un événement et fournissent des informations supplémentaires sur cette activité détectée.

Les fonctions de *reconnaissance* nécessitent le plus haut niveau de l'analyse. Elles sont obtenues en combinant l'information générée par les différentes détections, mesures et des connaissances préalables. Elles caractérisent le niveau le plus élevé d'abstraction de la situation et des actions du PwD. Elles exigent des processus basés sur la fusion de l'information et des méthodes de raisonnement.

La *connaissance sémantique* est incluse dans la base de connaissances en trois parties distinctes :

- La fonction de *Define Semantic Knowledge* adresse la partie intentionnelle de la base de connaissances décrite par des ontologies et des règles : à savoir les types d'entités, les propriétés et les faits généraux qui régissent le domaine du discours (e.g. la "pomme est un fruit").

- La fonction de *Populate Semantic Knowledge* adresse la partie extensionnelle de la base de connaissances décrite par les observations, les activités du patient PwD et leurs anomalies : à savoir les faits spécifiques sur des entités réelles et leurs interdépendances (e.g. "Alice mange une pomme").

- La fonction de *Personalize Semantic Knowledge* adresse la mise à jour dynamique du profil du patient PwD : à savoir l'identification des tendances et des changements au cours du temps, et l'enrichissement de la base de connaissances afin de permettre les inférences ajustées en fonction du patient PwD (i.e. ses activités, son évaluation, sa rétroaction,...).

Des résultats des expérimentations (notamment des interfaces graphiques, mais aussi des sources de données servant de tests) ne peuvent être montrés ici, au vu du caractère confidentiel des données de surveillance. Il y a, heureusement, une sécurité imposée au traitement de l'information que ce soit des données de capteurs, du stockage des observations analysées et des comptes-rendus (selon le patient et les droits de leurs personnels traitants). Néanmoins, nous pouvons citer ce que permet l'interface graphique pour

- un patient PwD : (1) connaître son agenda (i.e. le jour, ses rendez-vous, ses activités récentes), (2) lire ses messages, (3) appeler une personne (en cliquant sur son image qui est accompagnée de qui il est par rapport au PwD, tel que ses proches ou son médecin), (4) avoir des alertes (pour lui rappeler ses tâches quotidiennes lorsqu'elles ne sont pas effectuées, telles que se lever / coucher / laver, manger, prendre ses médicaments,...), et (5) suivre des exercices cognitifs et physiques.

- un soignant (i.e. des proches et des auxiliaires de vie) du PwD : savoir depuis combien de temps le PwD n'a eu de visites, d'être alerter lors d'anomalies (telle que lors d'une chute du PwD),...

- un médecin : gérer ses patients PwD, avoir les alertes et des statistiques basées sur les activités quotidiennes (à propos du sommeil, des repas, des exercices cognitifs et physiques, de ses interactions sociales,...).

- un administrateur : gérer les profils de patients et de ceux qui y accèdent, de mettre à jour le système, de vérifier l'état de marche du système,...

10.3 Conclusion

Pour les personnes atteintes de démence et leurs proches, il y a de nombreux **avantages** à utiliser le système Dem@care : un moindre coût (de l'absence d'une surveillance humaine constante), des alertes en quasi-temps réel, la journalisation de l'évolution de l'état de santé du patient, une aide à la personne et un traitement réellement personnalisé,... et surtout la possibilité que le patient reste autonome et indépendant dans sa vie personnelle (plutôt qu'une liberté réduite dans un institut adapté pour les cas les plus avancés).

Il est toutefois à prendre en compte la dimension éthique de projet, que ce soit en terme de surveillance (notamment les droits du patient) et en terme de présence sociale (puisque dans la dimension monétaire, remplacer le coût humain par un coût machine s'est souvent produit, ce qui diminuerait le nombre de contacts sociaux avec ces personnes qui en sont déjà souvent dépourvues).

Il est tout à fait honnête de penser que ce genre de système, s'il prouve sa viabilité durant les prochaines années, sera applicable pour d'autres environnements ayant un besoin constant de surveillance (tels que les prisons, les chantiers à risque, les lieux de soins, les zones d'interventions et de catastrophes,...), et aussi chez soi pour les personnes ayant des troubles, mais gardant leur indépendance (tels que des personnes à mobilité réduite ou ayant des problèmes cognitifs,...).

Dem@care nous a permis d'avoir **un rôle d'intégrateur** de différentes technologies de **surveillance des activités quotidiennes d'individus** ayant des forts risques de **comportements anormaux**. Le CEP

(traitement des événements complexes) nous donne le moyen de produire une détection de comportements individuels à un haut niveau d'information. Cette expérience a soutenu notre état de l'art et nous a donné des connaissances des niveaux 0 à 2 de la fusion de données pour obtenir une évaluation de la situation. Chose que nous avons laissée de côté pour nous concentrer sur les niveaux 2 à 3 afin de détecter les comportements collectifs.

Résumé

Ce manuscrit de thèse présente une méthode innovante brevetée pour la détection de comportements collectifs. En utilisant des procédés de fusion sur les données issues d'un réseau multi-capteurs, les récents systèmes de surveillance obtiennent les séquences d'observations des personnes surveillées. Ce bas niveau d'évaluation de la situation a été mesuré insuffisant pour aider les forces de sécurité lors des événements de foule. Afin d'avoir une plus haute évaluation de la situation dans ces environnements asymétriques, nous proposons une approche multi-agents qui réduit la complexité du problème par des agents sur trois niveaux - macro, méso et micro - d'observations. Nous utilisons un nouvel état relatif dans les approches de l'état de l'art pour nous permettre la détection, en temps réel, des groupes, de leurs comportements, objectifs et intentions. Dans le cadre de projets européens, nous avons utilisé un serious game simulant une foule dans des scénarios asymétriques. Les résultats montrent un meilleur accord avec les prédictions théoriques et une amélioration significative des travaux précédents. Le travail présenté ici pourrait être utilisé dans de futures études de détection de comportements multi-agents et pourrait un jour aider à résoudre les problèmes liés aux événements catastrophiques de foules incontrôlables.

Mots-clés : Intelligence artificielle répartie ; Comportement collectif ; Reconnaissance des formes (informatique) ; Systèmes mésoscopiques ; Fusion multicapteurs ; Guerre asymétriques.

Thesis title

Behaviour detection through semantically networked multi-agent models, applied to the situation awareness application domain, especially in asymmetric environment with uncertain and imprecise information.

Abstract

This PhD thesis presents a patented innovative method for the detection of collective behaviors. Using fusion processes on data captured from a multi-sensor network, recent monitoring systems obtain the observation sequences of monitored people. This lower level of situation awareness was measured to be not enough to help the security forces during crowd events. In order to have an incremented situation awareness in these asymmetric environments, we propose a multi-agent approach reducing the problem complexity by agents on three levels - macro, meso and micro - of observations. We use a new relative state within previous approaches enabling us the real-time detection of groups, their behaviors, their goals and their intentions. During European projects, we used a serious game simulating a crowd among asymmetric scenarios. Results show better agreement with theoretical predictions and significant improvement over previous efforts. The work presented here has profound implications for future studies of multi-agent behaviour detection and may one day help solve the problems during unmanageable events of disaster crowds.

Keywords : Distributed artificial intelligence ; Collective behaviour ; Pattern recognition systems ; Mesoscopic phenomena ; Multisensor data fusion ; Asymmetric warfare.