

Incidence de la régulation d'un
carrefour à feux sur le risque
subi par les usagers
Apprentissage d'indicateurs
par sélection de données dans un flux

Thèse

Présentée pour obtenir le grade de
**Docteur de l'École Nationale Supérieure des
Télécommunications**
(Spécialité : Informatique et Réseaux)

par

Nicolas Saunier

soutenue le 8 avril 2005 devant un jury composé de :

Michèle Sébag (LRI)	Président
Patrick Gallinari (LIP6)	Rapporteurs
Domenico Gattuso (DIMET)	
Sylvain Lassarre (INRETS)	Examineur
Alain Grumbach (GET-ENST)	Directeurs de thèse
Sophie Midenet (INRETS)	

"Of course," he says, "we have no idea, now, of who or what the inhabitants of our future might be. In that sense, we have no future. Not in the sense that our grandparents had a future, or thought they did. Fully imagined cultural futures were the luxury of another day, one in which 'now' was of some greater duration. For us, of course, things can change so abruptly, so violently, so profoundly, that futures like our grandparents' have insufficient 'now' to stand on. We have no future because our present is too volatile." He smiles a version of Tom Cruise with too many teeth, and longer, but still very white. "We have only risk management. The spinning of the given moment's scenarios. Pattern recognition."

W. Gibson, Pattern Recognition, Penguin.

Au ralenti, les véhicules expérimentaux s'approchaient les uns des autres sur les parcours de collision, déroulant derrière eux les filins près de la zone d'impact. Lorsqu'ils entraient en collision, les débris de portières et de vitres volaient dans l'air. Les autos s'abordaient en souplesse, comme des requins aimables, et poursuivaient ensuite leur course désintégratrice. Sur les sièges des passagers les mannequins en plastique exécutaient des trajectoires gracieuses entre le toit et les vitres. Ici et là, un pare-chocs sectionnait un torse et derrière les autos l'air s'emplissait d'un carnaval de bras et de jambes.

J. G. Ballard, La foire aux atrocités, Editions TRISTRAM.

I am a scientist
 Sitting in a laboratory
 Conducting experiment
 Analysing data.

Dopplereffekt, Scientist, album Gesamtkunstwerk, Phantom.

Résumé

Notre recherche s'inscrit dans le cadre de la régulation des carrefours à feux et du développement d'outils intégrés de gestion du trafic. Notre tâche consiste à construire un système d'analyse des données d'observation d'un carrefour, obtenues après traitement des images vidéo, afin d'évaluer l'impact relatif de différentes stratégies de régulation sur le risque des usagers. Pour cela, nous nous intéressons aux interactions entre véhicules et à leur relation à l'accident. Nous construisons des indicateurs pour analyser le fonctionnement d'un carrefour sous l'angle du risque subis par les usagers motorisés.

Nous utilisons un dispositif expérimental d'observation automatique d'un carrefour réel et les données d'une expérience pendant laquelle différentes stratégies de régulation des feux ont été appliquées. Nous disposons ainsi d'une base de données de huit mois d'enregistrements de scènes de trafic, ce qui nous permet de comparer l'incidence relative de deux stratégies, une stratégie de référence développée par les exploitants du carrefour et une stratégie adaptative temps-réel basée sur des capteurs vidéo, appelée CRONOS et développée à l'INRETS.

Les contributions de ce travail appartiennent à deux domaines, la sécurité et la gestion du trafic d'une part, l'apprentissage artificiel d'autre part.

L'hypothèse fondamentale de notre approche voit le trafic comme un ensemble d'interactions que l'on peut ordonner selon leur proximité à l'accident. Cette proximité est qualifiée de sévérité. Nous proposons une modélisation des interactions entre les véhicules dans un carrefour et nous intéressons à l'impact des stratégies sur la façon dont les véhicules sont mis en présence dans l'espace particulier de la zone de conflit. Nous mesurons les durées d'interactions et qualifions à chaque instant la sévérité des interactions détectées selon deux indicateurs de sévérité, un indicateur de proximité et un indicateur de vitesse.

Nous construisons un système modulaire qui permet de traiter automatiquement les données disponibles, i.e. détecter les interactions et estimer leur sévérité. Pour détecter les interactions, nous utilisons des règles explicites fournies par un expert. Pour les indicateurs de sévérité, nous développons une méthode d'apprentissage générique, par sélection de données dans un flux. Cette méthode est testée sur l'apprentissage de l'indicateur de vitesse. L'algorithme d'apprentissage est évalué sur d'autres problèmes classiques ("benchmarks").

Nous utilisons le système développé pour traiter une partie des données de la base. Grâce à ce système, nous étudions les distributions des durées d'interaction selon les indicateurs de sévérité et mettons en évidence des différences entre les stratégies comparées.

La méthode d'interprétation des résultats peut être employée dans tout diagnostic de sécurité fondé sur des interactions et leur sévérité.

Mots-clefs sécurité du trafic, interactions, indicateurs de sévérité, exposition au risque, apprentissage artificiel, sélection de données, algorithmes incrémentaux, combinaison d'hypothèses.

Abstract

This research deals with traffic light control strategies and the development of integrated devices for traffic management. Our task is to build a system that analyses observation data of an intersection, output by a video processing tool, in order to evaluate the comparative influence of different traffic control strategies on the risk of road users. For this purpose, we focus on interactions between vehicles, and their relation to accidents. We present indicators to analyse the functioning of an intersection in the perspective of the risk of road users.

We use an automated experimental observation device of a real intersection and the data provided by an experiment over a period of eight months during which time different traffic light control strategies were applied. The resulting database allows us to make a comparative analysis of the effects of two strategies, a reference strategy by the current managers of the intersection, and an adaptive real-time strategy, called CRONOS, developed in INRETS and based on video sensors.

Our contribution falls into two domains, traffic management and traffic safety on the one hand, and machine learning on the other hand.

The main hypothesis underlying our approach considers the traffic as a set of interactions that can be classified according to their proximity to accidents. This proximity is called severity. We introduce a categorization of interactions between vehicles in an intersection, and focus on the impact of strategies on the way vehicles are simultaneously accessing the particular area of the conflict zone. We measure the interaction duration and evaluate at each instant the severity of detected interactions, according to two indicators, a proximity indicator and a speed indicator.

We build a modular system that can automatically treat the available data, i.e. detect interactions and estimate their severity. For the detection of interactions, we use explicit rules provided by an expert. For the severity indicators, we develop a generic learning method, through data selection in a stream. This method is tested on the learning of the speed indicator. The learning algorithm is evaluated on other benchmark problems.

We use our system to analyse a part of the database. With this system, we study the distribution of interaction duration according to the safety indicators and highlight differences between the compared strategies. This approach can be applied for any safety diagnosis based on interactions and their severity.

Keywords traffic safety, interactions, safety indicators, risk exposure, machine learning, data selection, incremental algorithms, ensemble methods.

Remerciements

Il est maintenant venu le temps des remerciements. Ce travail a été financé par une bourse de l'INRETS, co-financée par la région Ile de France. Je remercie aussi Gérard Scémama, directeur du GRETIA, pour le prolongement de mon financement. Voici une liste de personnes qui m'ont aidé d'une façon ou d'une autre dans ce travail, et je m'excuse par avance auprès de celles que je pourrais oublier. Je tiens tout d'abord à remercier mes encadrants, Alain Grumbach et Sophie Midenet, pour leur disponibilité, la qualité de leur encadrement et leur exigence scientifique.

Je remercie aussi très chaudement les membres de mon jury pour leur travail, à commencer par mes rapporteurs, Domenico Gattuso et Patrick Gallinari. Je remercie aussi Michèle Sébag pour avoir assuré la présidence de ce jury et Sylvain Lassarre pour ses questions malgré son absence.

Je tiens à remercier les deux laboratoires dans lesquels cette thèse a été préparée pour leur accueil, le groupe I3 du département INFRES de l'ENST et l'unité de recherche GRETIA de l'INRETS. Je pense en particulier à mes (nombreux) compagnons de bureau, Nicolas (l'autre), Romain, Tuan Anh, Arnaud, Alexandre et Robert, les autres doctorants, Jean-Philippe, Nadine, Cyril, Eric, Baptiste... Sans oublier les autres membres d'I3 et d'INFRES, en particulier les thés et autres foies gras "improvisés" chez Jean-Louis, les pistaches de Laleh, les bouteilles et fromages d'Olivier, sans oublier Hayette, François, Jean-Marc et son travail pour le RAB, Talel, Isabelle pour m'avoir donné la chance d'enseigner, DJ Jean, Serge, Irène.

Du côté de l'INRETS, je n'oublierai pas les indispensables réunions Croissants Intelligents de l'équipe Carrefour Intelligent, orchestrées avec constance par Jean-Claude, régulièrement suppléées avec brio par les pâtisseries de Pierre, avec Florence, Olivier et Sophie. Je pense aussi à Pascal, Régine, Maurice, Mustapha, Mehdi, Thomas, Neila, Olivier, Gérard, Khaled, Mahdi, ainsi qu'aux documentalistes de l'INRETS pour leur compétence et rapidité.

Je remercie toutes les personnes qui m'ont donné un peu de leur temps pour discuter au cours de mon travail, par email ou lors de conférences, à l'INRETS, Nicole Muhlrud, Sylvain Lassarre, Farida Saad, Marie-Berthe Biecheler-Fretel, Jean-Michel Auberlet, Stéphane Espié, Dominique Fleury, Gilles Malaterre, les personnes de l'ICTCT, Åse Svensson, Christer Hydén, Richard van der Horst, Ezra Hauer ; du côté de l'Informatique, Fabien Torre, Henri Binsztok, Isabelle Bloch, Laurence Likforman... Je remercie aussi l'ABG¹ pour m'avoir

1. Association Bernard Gregory, <http://www.abg.asso.fr/>

permis de participer à la Valorisation des Compétences, et à Joël de Nervaux de m'avoir accompagné dans cet exercice.

Je remercie enfin les relecteurs courageux de mes écritures, mon frère Julien (bonne chance pour la tienne), Romain et Isabelle. Le dernier mot lui va, elle qui a vécu le côté obscur de la thèse et m'a toujours encouragé. Le plus dur est fait et le meilleur à venir.

Table des matières

1	Introduction	1
1.1	Contexte	1
1.2	La problématique	2
1.3	Contributions de ce travail	2
1.4	Plan du document	3
2	Le diagnostic de sécurité dans les carrefours	5
2.1	Introduction	5
2.1.1	Les éléments du monde	6
2.1.2	Le carrefour à feux	7
2.1.3	La régulation dans un carrefour à feux	8
2.2	La sécurité et le risque	11
2.2.1	Les interactions	11
2.2.2	Hypothèses fondamentales : la hiérarchie des interactions et la sévérité	12
2.2.3	Le risque	15
2.3	Les méthodes de diagnostic de sécurité	17
2.3.1	L'usage de l'exposition	17
2.3.2	L'analyse des accidents	19
2.3.3	Les Techniques des Conflits de Trafic	22
2.3.4	Autres méthodes de sécurité	29
2.4	Conclusion	30
3	Le diagnostic de sécurité pour notre problématique	33
3.1	Une modélisation des interactions	33
3.1.1	Quelles interactions ?	34
3.1.2	Les catégories d'interaction	35
3.1.3	Le risque et la sévérité	38
3.2	Le système expérimental	39
3.2.1	Le laboratoire Carrefour Intelligent	39
3.2.2	Le site expérimental	40
3.2.3	Les données	41
3.2.4	La base de données	44
3.3	Que détecter dans les données ?	46
3.3.1	Adaptations nécessaires	46

3.3.2	Quels indicateurs de sévérité?	47
3.3.3	Limites et discussion	51
3.3.4	Objectifs du travail et interprétation des données	52
3.4	Conclusion	54
4	Des règles pour les interactions et leur proximité	57
4.1	Introduction	57
4.1.1	Le contexte	57
4.1.2	Intelligence artificielle et systèmes experts	58
4.2	La détection des interactions	58
4.2.1	Les formes	59
4.2.2	Le franchissement de la ligne de feu	61
4.2.3	Les interactions	62
4.3	L'indicateur de proximité	65
4.3.1	Extrapolation des trajectoires	65
4.3.2	Calcul de l'indicateur de proximité	66
4.4	Validation	68
4.4.1	Introduction	68
4.4.2	La détection des interactions	69
4.4.3	L'indicateur de proximité	71
4.4.4	Remarques	72
4.5	Conclusion	73
5	L'apprentissage de la sévérité des interactions	75
5.1	Introduction à l'apprentissage	75
5.1.1	Système à base de règles et apprentissage	75
5.1.2	L'apprentissage artificiel	76
5.2	La problématique des indicateurs de sévérité	84
5.2.1	Les exemples	84
5.2.2	Les étiquettes de sévérité	86
5.2.3	Un algorithme incrémental pour traiter un flux de données	87
5.3	Apprentissage incrémental par sélection de données	92
5.3.1	Quels objectifs?	92
5.3.2	Introduction à l'apprentissage actif	94
5.3.3	Sélection de données dans un flux	96
5.3.4	Critère d'arrêt	101
5.3.5	Combiner les hypothèses pour améliorer la stabilité des performances	103
5.4	Etudes expérimentales et validation	108
5.4.1	Problèmes classiques	111
5.4.2	L'indicateur de vitesse	119
5.4.3	Conclusion	127
5.5	Perspectives et problèmes ouverts	127

6	Analyse comparative de stratégies de régulation	131
6.1	Les résultats	131
6.1.1	Présentation	131
6.1.2	Comparaisons	134
6.2	Conclusion	138
6.3	Limites et perspectives	139
7	Conclusion et perspectives	155
A	Les modules de détection des interactions	159
A.1	Introduction à G2	159
A.2	Les principes de nos modules G2	160
A.3	L'algorithme de construction des formes dans les images	161
A.4	Les règles pour le franchissement de la ligne de feu	162
B	Les modules d'apprentissage	165
B.1	Introduction	165
B.2	Les modules programmés	166
B.2.1	Les données	166
B.2.2	L'apprentissage	167
B.2.3	Les utilitaires	170
B.3	Temps de calcul des algorithmes d'apprentissage	171
C	Valorisation des compétences	175
C.1	Cadre général et enjeux de ma thèse	175
C.2	Contexte	176
C.3	Conduite du projet	178
C.3.1	Gestion du temps	178
C.3.2	Gestion des relations extérieures	178
C.3.3	Budget et financement	179
C.4	Compétences développées dans le cadre de mon projet	180
C.5	Conclusion	181
	Bibliographie	182
	Index	193

"Un trait, entre tous distinctif, oppose la civilisation contemporaine à celles qui l'ont précédée : la vitesse. La métamorphose s'est produite en l'espace d'une génération", constatait dans les années trente l'historien Marc Bloch (1930).

Avertissement pour l'exposition
"Ce qui arrive",
Paul Virilio

1

Introduction

Sommaire du chapitre

1.1	Contexte	1
1.2	La problématique	2
1.3	Contributions de ce travail	2
1.4	Plan du document	3

1.1 Contexte

Le risque est une notion qui a envahi le monde moderne occidental. Un livre développe ainsi le concept de "société du risque" (Beck, 1986). L'émergence récente dans les media des expressions "risque zéro" et "principe de précaution" met l'accent sur cette obsession. Ainsi, du 29 novembre 2002 au 30 mars 2003 à la Fondation Cartier pour l'art contemporain, il était possible de voir "Ce qui arrive" (définition du latin *accidens*) une exposition conçue par Paul Virilio¹. Au travers de la vision artistique de différentes formes de l'accident, cette exposition montrait à quel point l'accident est constitutif des sociétés technologiques modernes (cf citation en exergue). La tendance qui nous expose à l'accident se trouvait alors renversée en exposant l'accident à son tour dans ce qui constitue un musée de l'accident.

Pour parler plus précisément du risque qui nous occupe, le risque routier, un rapport de l'Organisation Mondiale de la Santé de 2004 indique que le trafic routier sera en 2020 la troisième cause la plus importante de dommages corporels dans le monde². En France, après un effort historique, le nombre annuel de morts sur les routes a amorcé une baisse

1. <http://www.onoci.net/virilio/index.php>

2. "the WHO has predicted that Road traffic injuries will in 2020 have the third-largest negative health impact world-wide", Peden M., Scurfield R., Sleet D., Mohan D., Hyder A.A., Jarawan E. & Mathers C. (eds.) 2004, World report on road traffic injury prevention, World Health Organisation, Geneva

depuis 2002, passant de 7720 en 2001 à 5217 en 2004. Pour s'approcher de la "Vision Zéro" suédoise, i.e. zéro mort sur les routes, il est nécessaire de développer de nouveaux outils pour diagnostiquer la sécurité, sans attendre que l'accident se produise.

1.2 La problématique

Notre recherche s'inscrit dans le cadre de la régulation des carrefours à feux et du développement d'outils intégrés de gestion du trafic. Une particularité de notre travail est l'utilisation de capteurs vidéo. Nous utilisons un dispositif expérimental d'observation automatique d'un carrefour réel, appelé laboratoire "Carrefour Intelligent", sur les données duquel nous nous appuyons. Une expérience a été menée sur ce carrefour pendant laquelle différentes stratégies de régulation des feux ont été appliquées. Nous disposons ainsi d'une base de données de huit mois d'enregistrements de scènes de trafic, ce qui nous permet de comparer l'incidence relative de deux stratégies, une stratégie de Référence développée par les exploitants du carrefour et une stratégie innovante adaptative basée sur des capteurs vidéo, appelée CRONOS et développée à l'INRETS.

Notre tâche consiste à construire un système de traitement des données dynamiques d'occupation du carrefour provenant de plusieurs capteurs vidéo. Nous analysons ces données afin d'évaluer l'impact relatif des stratégies de régulation sur le risque des usagers. Pour cela, nous nous intéressons aux interactions des usagers et à leur relation à l'accident. Nous construisons des indicateurs pertinents pour analyser le risque subis par les usagers et le fonctionnement du carrefour.

1.3 Contributions de ce travail

Nous distinguons les contributions de ce travail dans deux domaines, la sécurité et la gestion du trafic d'une part, l'apprentissage artificiel d'autre part.

Nous appelons mobile tout ensemble d'un véhicule avec son conducteur. L'hypothèse fondamentale de notre approche voit le trafic comme un ensemble d'interactions réparties en classes plus ou moins "proches" de l'accident. Cette "proximité" est qualifiée de sévérité. Dans la perspective de comparer l'influence des stratégies de régulation sur le risque d'accident, nous proposons une *modélisation des interactions* entre les mobiles dans un carrefour. Pour cela, nous nous intéressons à l'impact des stratégies sur la façon dont les mobiles sont mis en présence dans l'espace particulier d'une zone de conflit. La zone de conflit est la zone d'un carrefour dans laquelle des mobiles provenant de différentes origines se croisent. Nous mesurons les durées d'interactions et qualifions à chaque instant la sévérité des interactions détectées selon deux indicateurs de sévérité, un indicateur de proximité et un indicateur de vitesse.

Nous construisons un *système modulaire* qui permet de traiter automatiquement les données disponibles, i.e. détecter les interactions et estimer leur sévérité. Pour détecter les interactions, nous utilisons des règles explicites fournies par un expert. Pour les indi-

cateurs de sévérité, nous développons une *méthode d'apprentissage générique*, par sélection de données dans un flux. Nos méthodes sont testées sur notre problème. Les algorithmes d'apprentissage sont évalués sur d'autres problèmes classiques ("benchmarks").

Nous utilisons le système développé pour traiter une partie des données de la base constituée lors de l'expérience. Grâce à ce système, nous étudions les distributions des durées d'interaction selon les indicateurs de sévérité et mettons en évidence des différences entre les stratégies comparées. La *méthode d'interprétation* des résultats peut être employée dans tout diagnostic de sécurité basé sur des interactions et leur sévérité.

1.4 Plan du document

Cette thèse est constituée de sept chapitres principaux, dont le premier est cette introduction, le dernier une conclusion, suivis d'annexes.

Le chapitre 2 passe en revue les méthodes de diagnostic de la sécurité les plus courantes dans un carrefour. Après avoir décrit un carrefour, nous introduisons les événements élémentaires du trafic pour notre étude, les interactions entre mobiles. Nous présentons le trafic dans une perspective de sécurité, en nous appuyant principalement sur les approches suédoises. Le trafic est vu comme une hiérarchie de sécurité selon la proximité spatio-temporelle des événements du trafic à l'accident, appelée sévérité. Nous introduisons la notion de risque d'accident à partir de la sévérité et de la gravité de l'accident potentiel.

Nous proposons ensuite dans le chapitre 3 une modélisation des interactions en catégories basée sur les zones fonctionnelles d'une intersection, suivant le cheminement d'un mobile dans une intersection. Nous présentons le site expérimental, les données traitées et l'expérience qui y a été menée. Nous simplifions les objectifs de notre travail en fonction des caractéristiques des données. Nous détectons les interactions entre mobiles dans ou proches de la zone de conflit et estimons leur sévérité selon les deux indicateurs de proximité et de vitesse. Nous mesurons la durée d'interaction de chaque catégorie.

Le système de traitement des données se compose de deux modules, un premier qui détecte les interactions, et un second qui estime leur sévérité selon les deux indicateurs. Le chapitre 4 décrit les règles explicites d'interprétation des données qui permettent de détecter les interactions et de calculer l'indicateur de proximité. Ces règles sont validées sur les données.

Dans le chapitre 5, nous proposons une solution originale pour apprendre tout indicateur de sévérité, utilisée dans notre travail pour l'indicateur de vitesse. Après avoir présenté les caractéristiques du problème, nous mettons en oeuvre un algorithme de sélection des données pour améliorer les performances des hypothèses construites, en particulier sur les exemples proches des frontières entre les classes de l'indicateur. Nous combinons les hypothèses construites pour obtenir des hypothèses plus stables. Nous testons les performances des algorithmes présentés sur l'apprentissage de l'indicateur de vitesse, ainsi que sur des problèmes d'apprentissage classiques.

Nous pouvons enfin étudier l'impact des stratégies de régulation sur les interactions entre mobiles et leur sévérité dans le chapitre 6. En interprétant les distributions des durées d'interaction selon les indicateurs de sévérité, nous traitons une partie de la base de données de l'expérience et comparons la stratégie innovante CRONOS à une stratégie de référence.

Enfin, nous concluons cette thèse au chapitre 7 en résumant les contributions de ce travail et en présentant des perspectives de nos travaux.

*L'horreur d'un accident qu'on découvre
sur sa route provient de ce qu'il est de la
vitesse immobile, un cri changé en silence
(et non pas du silence après un cri).*

La machine infernale,
Jean Cocteau

2

Le diagnostic de sécurité dans les carrefours

Sommaire du chapitre

2.1	Introduction	5
2.1.1	Les éléments du monde	6
2.1.2	Le carrefour à feux	7
2.1.3	La régulation dans un carrefour à feux	8
2.2	La sécurité et le risque	11
2.2.1	Les interactions	11
2.2.2	Hypothèses fondamentales : la hiérarchie des interactions et la sévérité	12
2.2.3	Le risque	15
2.3	Les méthodes de diagnostic de sécurité	17
2.3.1	L'usage de l'exposition	17
2.3.2	L'analyse des accidents	19
2.3.3	Les Techniques des Conflits de Trafic	22
2.3.4	Autres méthodes de sécurité	29
2.4	Conclusion	30

2.1 Introduction

Un diagnostic de sécurité s'appuie en général sur le relevé de certains événements du trafic comme les accidents. Les accidents sont-ils les seuls événements qui permettent d'étudier le risque et le comportement des usagers dans les carrefours ? Sont-ils les plus pertinents ? Nous définissons d'abord les entités élémentaires traitées dans ce travail, discutons les types d'événements du trafic les plus intéressants, les accidents, les conflits de trafic et plus généralement toutes les interactions entre usagers.

2.1.1 Les éléments du monde

Le trafic routier est un système complexe, dans lequel interagissent de très nombreux acteurs. Le monde que nous étudions se divise en trois ensembles d'entités :

les usagers : les usagers sont les êtres humains présents sur la route, i.e. la chaussée ou les trottoirs. Ils peuvent conduire un véhicule ou circuler à pieds (*piéton*). Les usagers les plus vulnérables dans le trafic et les moins susceptibles de causer des dommages aux autres usagers sont appelés usagers *vulnérables* : il s'agit essentiellement des piétons et des conducteurs de deux-roues.

les véhicules : les usagers utilisent un véhicule pour se déplacer sur les routes. On peut distinguer les véhicules légers, les poids lourds, les transports en commun, et les deux-roues.

l'environnement : le reste, i.e. tous les éléments inertes du système routier font partie de l'environnement. Les éléments notables d'infrastructure sont la chaussée, le trottoir, les constructions, les feux de circulation, le mobilier urbain. Un sous-ensemble de l'environnement pertinent pour la sécurité est celui des éléments avec lesquels un véhicule peut entrer en collision, que l'on qualifie d'*obstacle*.

Deux précisions à ces définitions. La première concerne l'appartenance à la catégorie obstacle de certains véhicules à l'arrêt. Nous faisons la différence entre les véhicules en déplacement sur un carrefour, qui peuvent être à l'arrêt momentanément selon le trafic, et les véhicules en arrêt pour une longue période. L'ensemble constitué par un usager avec le véhicule qu'il conduit ou simplement un piéton définit un *mobile*. Les piétons s'intègrent dans notre cadre, mais ne sont pas étudiés dans nos travaux pour des raisons liées aux données expliquées plus tard. Nous n'étudions pas non plus les obstacles dans ce travail. Un mobile est un usager en déplacement, avec ou sans véhicule. C'est le sujet principal des études que nous présentons ici. Nous ne rappelons pas dans la suite les définitions classiques d'ingénierie du trafic, en particulier les variables courantes. Le lecteur peut se référer pour cela à (Cohen, 1993).

Il nous faut aussi préciser nos capacités d'observation car les descriptions des événements du trafic doivent y être adaptées pour être opérationnelles dans notre système automatique. Nous décrivons plus tard les capteurs dont nous disposons pour étudier le trafic. En particulier, ils nous permettent de percevoir les mouvements des mobiles, mais pas d'étudier la psychologie des usagers, leurs motivations et états d'esprit, éléments que nous ne pouvons pas faire entrer en jeu pour définir les événements étudiés dans le trafic. Nous qualifions nos capacités d'observation du trafic d'*extérieures*, i.e. extérieures au mobile.

Lorsqu'ils se déplacent sur le réseau routier, les mobiles entrent en interaction les uns avec les autres. Nous étudierons la relation de ces interactions à la sécurité dans la suite.

2.1.2 Le carrefour à feux

Nous reprenons dans cette partie un certain nombre de définitions du guide de l'AFNOR (Anonymous, 1991). Nous étudions le trafic routier dans une partie particulière de l'environnement, les carrefours à feux. Les carrefours sont des lieux critiques pour la sécurité des personnes qui s'y déplacent. Le *carrefour* est le lieu de croisement d'au moins deux routes. Ces routes sont caractérisées par leur largeur, le nombre de voies et le sens de circulation sur ces voies. Les routes se croisent de nombreuses façons, tant du point de vue de l'infrastructure que des règles de franchissement. La figure 2.1 représente un carrefour simple de deux routes à sens unique, qui sera appelé plus spécifiquement intersection dans la suite, et précise les *zones fonctionnelles* : la zone de conflit, avec deux zones de stockage en amont des lignes de feux. Un carrefour peut être très complexe, composé en fait d'un ensemble de carrefours plus simples suffisamment rapprochés et imbriqués les uns dans les autres pour apparaître aux yeux de l'utilisateur comme un seul carrefour. Nous nous intéressons dans ce travail à un type particulier de carrefour, les *carrefours à feux*, dont l'accès est contrôlé par des signaux lumineux d'intersection situés sur chaque voie d'entrée sur le carrefour. La signalisation lumineuse d'intersection couvre l'ensemble des signaux lumineux d'intersection tricolores, piétons et d'anticipation. Nous nous intéressons par la suite essentiellement aux *signaux tricolores*, appelés aussi *feux tricolores* ou *de circulation*. Un feu tricolore est caractérisé par sa couleur (vert, jaune ou rouge), un éventuel pictogramme désignant l'utilisateur concerné et le fait qu'il clignote ou pas. La façon de gérer les feux de circulation constitue la *méthode* ou *stratégie de régulation* du carrefour à feux et est discutée dans la partie suivante.

Un *mouvement* est défini par son origine et sa destination. A chaque type de mouvement ne correspond pas une voie dédiée. Ils sont regroupés par deux ou trois sur une même voie mixte et constituent des *courants*. Un courant de véhicule est défini comme l'ensemble des mouvements de véhicules provenant d'une même branche d'accès à un carrefour et admis simultanément au moyen d'un même groupe de signaux. Un *point conflictuel* résulte de la rencontre, en un même lieu, de mouvements antagonistes de mobiles. Certains trouvent une solution dans le respect des règles du Code de la Route, mais ils doivent être examinés avec soin en fonction de la visibilité et de l'importance respective des mouvements (cf la réglementation en vigueur dans (Anonyme, 1996)). D'autres doivent être systématiquement éliminés dès lors que l'on implante une signalisation lumineuse d'intersection. La *zone de conflit* est constituée des points conflictuels du carrefour.

La durée pendant laquelle un ou plusieurs courants sont admis simultanément dans le carrefour constitue une *phase*. L'enchaînement des différentes phases constitue le *cycle* des feux. Le cycle désigne aussi la durée entre deux passages successifs de l'ensemble des feux d'un carrefour à feux par le même état, en supposant que des phases ne sont pas escamotées. Dans ce cas, la stratégie est dite *acyclique*. Un *plan de feux* est l'ensemble des données définissant tout ou partie du fonctionnement d'un carrefour à feux, ou d'un

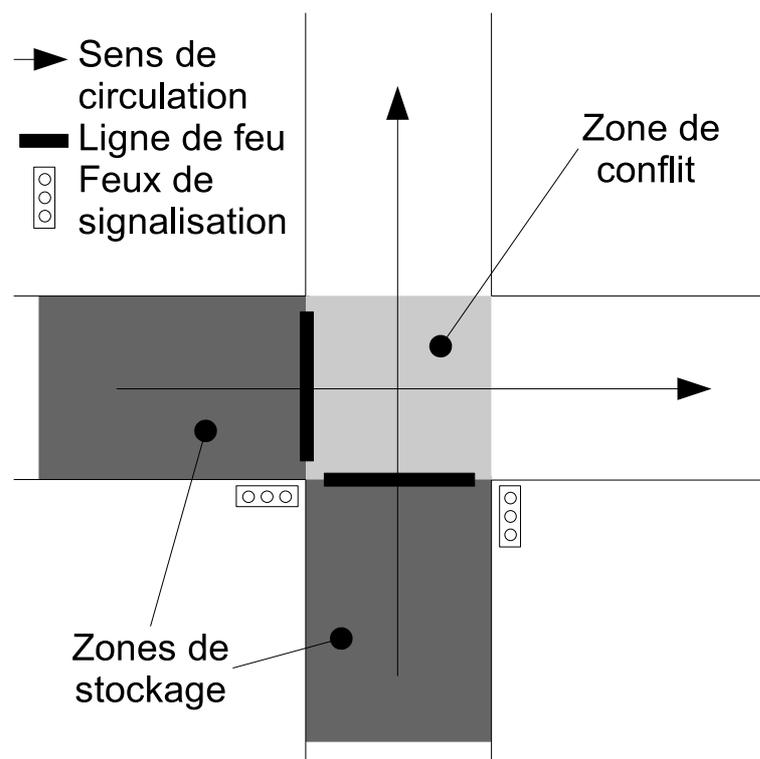


FIGURE 2.1 – Une intersection : carrefour simple de deux routes à sens unique.

ensemble de carrefours à feux, en particulier les phases du carrefour, leur succession et leur durée.

2.1.3 La régulation dans un carrefour à feux

La régulation du trafic en milieu urbain se donne différents objectifs (cf (Braban et Boillot, 2003; Anonyme, 1988)) : avant tout assurer la sécurité des usagers sur la voirie, en particulier dans les carrefours où les points conflictuels sont les plus nombreux, mais aussi maîtriser les retards, les congestions, la pollution, le bruit, conséquences d'une augmentation incessante du trafic, enfin assurer un certain confort.

Pour répondre à ces objectifs, la régulation revêt plusieurs aspects : d'abord un aspect statique par le choix d'une infrastructure urbaine doublée d'une signalisation appropriée ; ensuite un aspect dynamique par des actions sur les flux de mobiles au moyen de feux tricolores, de la présence d'agents de la circulation, de panneaux à messages variables et de systèmes embarqués d'information et de guidage. Nous nous intéressons dans ce travail aux méthodes de régulation par les feux tricolores.

La régulation par les feux

Les feux tricolores permettent de faire beaucoup de choses. En premier lieu, ils permettent de supprimer certains points conflictuels en partageant dans le temps l'utilisation d'un même espace, la zone de conflit précisément, entre des flux conflictuels. Par le choix

des durées de chaque état des feux¹, et la synchronisation des feux entre eux, ils permettent aussi de gérer l'écoulement de la demande.

Une des difficultés tient à la variabilité de la demande du trafic. La demande de trafic sur une entrée de carrefour varie de façon importante au cours d'une même journée, d'un jour ouvrable à un jour de fin de semaine, et une exploitation en temps fixe (phases et cycles fixés) ne permet pas d'offrir un bon niveau de service aux usagers. Il y a deux types de variations de trafic, celles régulières et prévisibles, et les autres exceptionnelles et aléatoires. Par exemple, les migrations pendulaires des jours ouvrables (soir et matin) sont à l'origine d'importantes variations régulières. Les périodes de vacances, manifestations populaires, sont sources de variations exceptionnelles.

Il faut donc chercher à adapter l'offre de l'infrastructure à la demande du trafic, selon différents critères, comme le temps d'attente de tel ou tel type d'utilisateur, le nombre d'arrêts, la consommation de carburant, la pollution, tout en assurant une sécurité maximale pour les usagers. Tous ces critères d'optimisation s'opposent parfois, en particulier ceux qui favorisent les différentes classes d'utilisateurs (par exemple les automobilistes, les piétons, et les transports en commun).

Différentes méthodes et une multitude d'outils existent pour cela. Le plan de feux fixe dans le temps reste la base d'un système de gestion des feux. S'y ajoutent des méthodes pour tenir compte des fluctuations du trafic (cf (Braban et Boillot, 2003; Anonyme, 1988)),

la programmation horaire (aussi appelée multiprogrammation à temps fixe) pour les variations régulières et prévisibles. Cette méthode consiste à disposer de plusieurs plans de feux correspondant aux situations types prévisibles du trafic et à les mettre en œuvre selon un calendrier programmé. Souvent, trois plans de feux suffisent, les heures de pointe (matin, midi et soir), les heures creuses du jour et les heures creuses de la nuit. Une méthode classique de calcul des carrefours à feux est décrite dans (Cohen, 1993),

la micro-régulation pour les variations exceptionnelles et aléatoires, prenant en compte l'analyse instantanée de la demande pour modifier la durée, l'occurrence ou l'ordre des phases dans le déroulement d'un plan de feux. Elle agit uniquement à l'échelle d'un carrefour ou d'un petit ensemble de carrefours,

la macro-régulation pour tous les types de variations, agissant à l'échelle d'une partie du réseau (regroupant plusieurs carrefours) sur des durées plus longues, pour coordonner ces carrefours. L'INRETS a développé un programme baptisé CLAIRE (Scemama, 2002), pouvant s'interfacer avec des méthodes de micro-régulation : il détecte les congestions, et donne des recommandations pour chaque axe (favoriser ou retenir le trafic) (Scemama, 2002).

Ces méthodes ne s'opposent pas et doivent être utilisées en parallèle. Elles assurent au système de gestion à base de plans de feux une adaptation au trafic non négligeable et

1. En France, la durée de l'orange est fixée par la réglementation.

une efficacité réelle dans de larges plages de fonctionnement, dans la mesure où un suivi et une maintenance du système sont assurés.

Les stratégies adaptatives

Depuis une vingtaine d'années est apparue une nouvelle famille de systèmes dits *temps réels* ou *adaptatifs* qui tendent à se démarquer des traditionnels plans de feux en offrant davantage de souplesse dans le choix des états de feux et en permettant de s'adapter à l'évolution du trafic au cours des années sans nécessiter une réactualisation comme dans le cas des plans de feux.

(Braban et Boillot, 2003) propose un panorama très complet de ces nouveaux systèmes. Nous illustrons cette présentation de la régulation du trafic dans les carrefours à feux en nous attachant sur un système développé à l'INRETS dans le laboratoire Carrefour Intelligent, *CRONOS*, que nous étudions dans la suite et qui a fait l'objet de nombreux travaux (Boillot *et al.*, 1992; Midenet *et al.*, 1999; Midenet *et al.*, 2000; Boillot *et al.*, 2000; Boillot, 2002b; Midenet *et al.*, 2004).

CRONOS est un système de régulation temps réel par commande de feux. Il s'applique à des carrefours simples ou complexes, et à des réseaux de carrefours. Son originalité est de ne pas utiliser le concept de cycle de feux, ni de phases de trafic à priori. Le carrefour se définit uniquement par des contraintes sur les groupes de feux appelées "contraintes de sécurité", définissant l'ensemble des états de feux interdits sur le carrefour pour des raisons de sécurité. *CRONOS* nécessite à chaque seconde des mesures de débit, de longueur de file d'attente et d'occupation sur tout le carrefour. Des capteurs vidéo sont les plus adaptés pour fournir ce type d'information. Le critère de trafic optimisé par *CRONOS* est le temps d'attente global au carrefour de l'ensemble des véhicules sur un certain horizon de temps. Il utilise pour cela un modèle prédictif, explore les différentes solutions possibles et choisit chaque seconde par la méthode d'optimisation *BOX* une des meilleures solutions.

Le système a été testé en situation réelle (Boillot *et al.*, 2000), et comparé à une stratégie de référence, un plan de feux avec micro-régulation. Les gains sont importants. Non seulement un véhicule gagne en moyenne 20% sur son temps d'attente, mais aussi 11% sur son nombre d'arrêts au carrefour. Les comparaisons en émission de CO_2 et en consommation de carburant, estimées par modélisation, révèlent aussi des gains intéressants (Midenet *et al.*, 1999; Midenet *et al.*, 2000; Midenet *et al.*, 2004) : par exemple, pour la catégorie des véhicules à essence équipés de pots catalytiques, est observé un gain de l'ordre de 4% pour le coût brut de traversée de la zone du carrefour (400 mètres) et de l'ordre de 14% sur la part due à l'arrêt dans ce coût.

2.2 La sécurité et le risque

2.2.1 Les interactions

Le trafic est un système complexe, résultant de l'ensemble des comportements individuels de ses multiples acteurs, et de leurs interactions.

Les interactions constituent la première classe d'évènements pertinents : dans une circulation fluide, peu dense ou sans difficultés de conduite particulières, une proportion importante des usagers [mobiles] effectuent leur déplacement sans interactions, c'est à dire sans avoir à modifier leur trajectoire ou leurs manœuvres en fonction d'autres usagers présents simultanément sur les lieux. (Muhlrad, 1988)

Nous parlerons dans ce cas de *mobiles isolés*. Dans le cas contraire, lorsque deux mobiles sont mis en présence et doivent tenir compte l'un de l'autre dans leur mouvement, il y a *interaction*. Cela implique une certaine proximité spatio-temporelle. Il y a des interactions permanentes entre un mobile et son environnement, entre plusieurs mobiles : l'utilisateur doit tenir compte en permanence des autres entités présentes sur la route, car ils partagent le même espace. Cette définition n'est cependant pas opérationnelle en tenant compte de nos capacités d'observation. Nous ne pouvons pas détecter de l'extérieur la prise de conscience par un usager de la présence d'un autre usager. Cette prise de conscience peut induire un changement de comportement observable, mais pas dans tous les cas. Nous définissons alors une *interaction potentielle* de la façon suivante.

Définition 2.2.1 *Deux mobiles sont en interaction potentielle s'ils sont proches spatialement et que leur distance diminue.*

Ainsi, sur la plupart des carrefours, tous les mobiles se rapprochant les uns des autres sont en interaction potentielle les uns avec les autres. Avec cette définition, un mobile est isolé soit s'il est trop éloigné des autres mobiles, soit s'il s'éloigne de tous les mobiles proches. Au bout d'un certain temps, tous les mobiles suffisamment proches sont ou ont été en interaction potentielle. Pour la suite, nous utilisons simplement le terme d'*interaction*. Plusieurs mobiles peuvent être en interaction à un instant donné, mais nous nous ramenons toujours à des interactions entre deux mobiles, en analysant les interactions entre mobiles deux à deux. Les mobiles en interactions sont qualifiés de *protagonistes* ou *impliqués*.

Dans ce travail, nous voulons évaluer la sécurité des usagers. La sécurité peut renvoyer à des acceptions très différentes selon les usagers et les intervenants. La sécurité, ou plutôt l'insécurité, est caractérisée par l'occurrence d'accidents. L'accident marque le dysfonctionnement du système.

Définition 2.2.2 *Un accident est un événement du trafic impliquant un mobile qui entre en collision avec au moins un obstacle ou un autre mobile, avec dommages matériels et/ou corporels*

pour les usagers. La gravité d'un accident mesure les conséquences de l'accident, i.e. les dommages causés par l'accident.

2.2.2 Hypothèses fondamentales : la hiérarchie des interactions et la sévérité

Les chercheurs suédois de l'université de Lund, C. Hydén et Å. Svensson, font l'hypothèse que les événements du trafic peuvent se répartir en différentes classes selon leur rapport à la sécurité, i.e. à l'accident (Hydén, 1987; Svensson, 1998). Ces classes d'événements plus ou moins sûrs peuvent être placées dans une *hiérarchie* des événements de trafic selon leur sécurité, ou *hiérarchie de sécurité*, avec les accidents à leur sommet.

Dans cette hiérarchie de sécurité, plus une interaction est "loin" de l'accident, plus elle est sûre. Il est possible de construire de proche en proche des classes d'interactions de plus en plus sûres. Les interactions les plus proches des accidents, i.e. dont le déroulement est très proche de celui d'un accident, sans collision, sont appelées les *quasi-accidents*. Après les quasi-accidents, peuvent être définis des "quasi-quasi-accidents", interactions très proches des quasi-accidents, dans lesquels par exemple les mobiles sont moins proches et les manœuvres d'évitement sont moins urgentes ... Il est possible d'envisager récursivement toute une hiérarchie des interactions selon leur proximité à l'accident. A la notion de hiérarchie peut être ajoutée celle de *pyramide*, introduite par (Hydén, 1987), indiquant que plus les situations sont éloignées de l'accident, plus elles sont fréquentes dans le trafic. Nous nous intéressons uniquement aux accidents entre mobiles. La situation la plus sûre est donc un mobile isolé. Les situations plus sévères, minimales pour qu'un accident ait lieu, sont les interactions. Les interactions sont les événements du trafic élémentaires considérés.

Nous reprenons l'hypothèse selon laquelle

Hypothèse 1 *Les interactions du trafic peuvent se placer sur une hiérarchie selon leur rapport à la sécurité, hiérarchie dite de sécurité.*

Attardons-nous sur la description d'un quasi-accident, qui nous permet de décrire différentes situations d'interaction entre mobiles. Trois notions classiques introduites dans les techniques des conflits de trafic interviennent dans la définition (Hydén, 1987; Muhlrad, 1988; Svensson, 1998) :

trajectoire de collision : deux mobiles sont sur une trajectoire de collision à un instant donné dans le cas où, si leurs trajectoires sont extrapolées à partir de cet instant selon des hypothèses à préciser, ils entreraient en collision en un *point de collision potentielle*. Les mobiles protagonistes sont alors en *interaction critique*.

manœuvre d'évitement : action entreprise par un protagoniste afin de quitter une trajectoire de collision, en changeant de vitesse et/ou de direction. Elle est plus ou moins urgente. L'évitement constitue une rupture visible dans la continuité du déplacement, comme un freinage ou un écart brusque.

accident potentiel : accident qui se produirait s'il n'y avait pas de manœuvres d'évitement ou si elles échouaient.

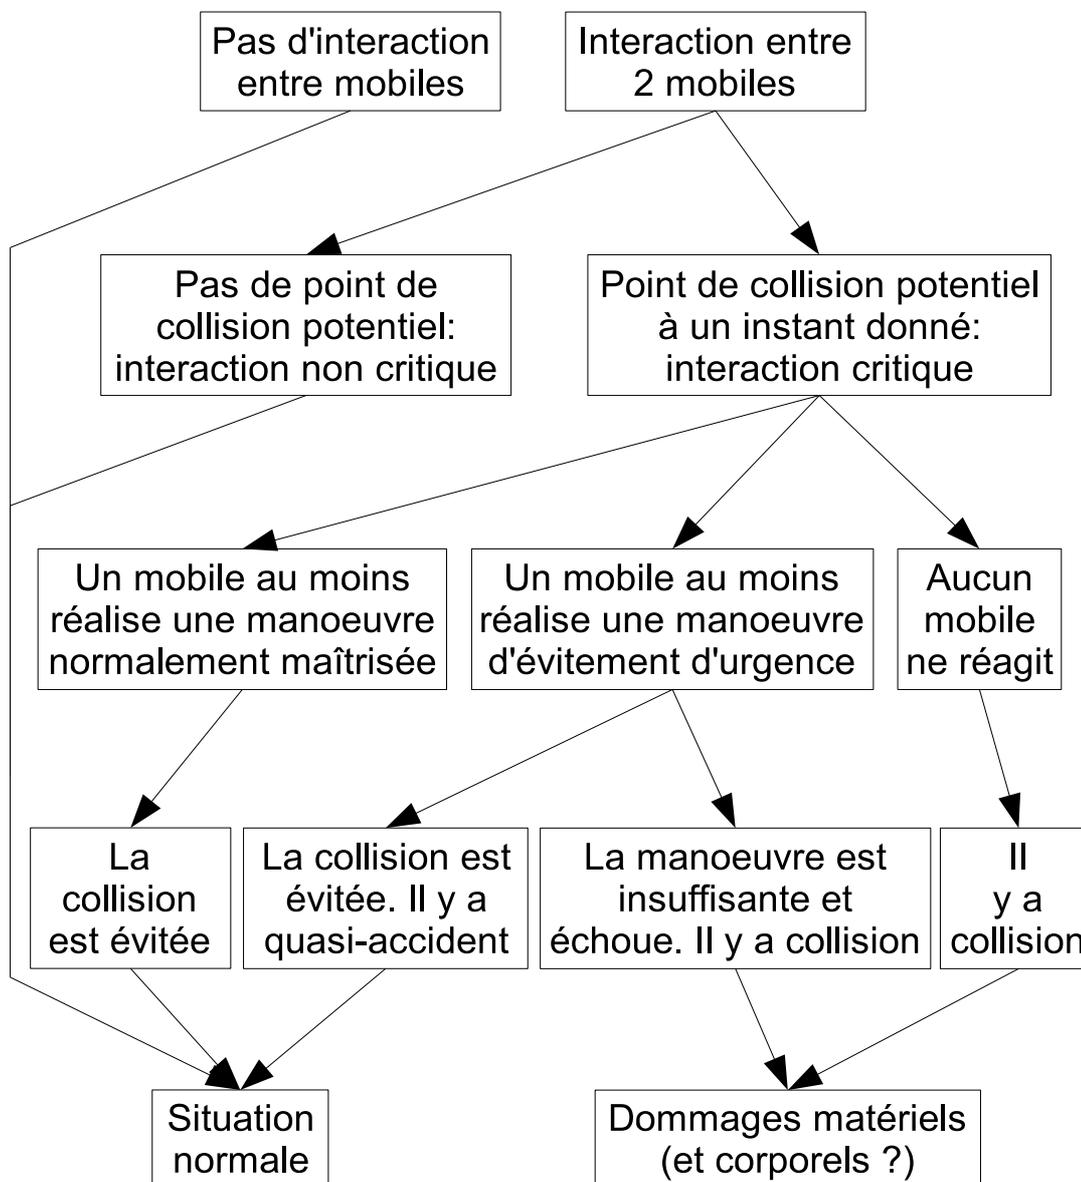


FIGURE 2.2 – Une description de différentes situations d'interaction entre l'accident et la situation normale de conduite.

Un quasi-accident est une interaction critique dans laquelle la manoeuvre d'évitement est brusque car elle intervient alors que la collision est imminente. A l'aide de ces termes, la figure 2.2, grandement inspirée de (Muhhrad, 1988), décrit différentes situations d'interaction, plus ou moins proches de l'accident, et les processus qui y mènent. Il faut nuancer la capacité descriptive de la notion de trajectoire de collision. Il existe en effet des interactions très dangereuses entre mobiles sans trajectoire de collision. Lorsque les trajectoires extrapolées des mobiles sont telles qu'ils passent très près l'un de l'autre, ou se dépla-

cent parallèlement, ils ne sont pas sur une trajectoire de collision (Wakabayashi et Renge, 2000). Or ces interactions peuvent être très dangereuses, un petit changement de trajectoire de l'un des mobiles pouvant les mettre sur une trajectoire de collision imminente. Il faut étendre la notion de trajectoire de collision (Wakabayashi et Renge, 2000), en considérant par exemple une "aire de danger" autour du mobile² pour décrire l'ensemble des interactions dangereuses dans ce cadre. Nous n'étudions pas ces cas dans la suite, pour des raisons liées aux données.

A partir de l'hypothèse de l'existence d'une hiérarchie de sécurité des interactions, est définie l'*échelle de sévérité* comme la traduction de la hiérarchie de sécurité en éléments mesurables (selon des hypothèses à préciser) (Svensson, 1998). Nous reprenons l'hypothèse suivante,

Hypothèse 2 *La sévérité est une valeur qui peut être estimée pour tout type d'interaction et reflète sa position dans la hiérarchie de sécurité.*

La sévérité d'une interaction est reliée à la *probabilité* que l'interaction évolue en accident, i.e. la probabilité conditionnelle qu'une collision ait lieu entre deux protagonistes, sachant que l'interaction entre ces protagonistes a été observée (Hydén, 1987; Svensson, 1998). Cette probabilité peut être obtenue comme le rapport du nombre d'interactions ayant évolué en accident, sur le nombre d'interactions, en observant assez longtemps le trafic pour que les fréquences des interactions soient de bonnes estimations de leur probabilité.

(Muhrad, 1988) décrit les facteurs principaux constituant la sévérité pour les interactions critiques :

- le degré d'urgence de l'évitement, i.e. la marge de manœuvre avant la collision potentielle,
- l'intensité des manœuvres d'évitement des mobiles impliqués,
- l'efficacité finale de l'évitement, i.e. la proximité des usagers à l'issue de l'évitement.

Les usagers peuvent réagir très brusquement parce qu'ils interprètent mal la situation, alors qu'une manœuvre normale serait suffisante. Pour cette raison, nous écartons le facteur de l'intensité des manœuvres d'évitement. La sévérité revient alors à une proximité dans le temps et l'espace des mobiles protagonistes, proximité qui leur laisse plus ou moins de *marge de manœuvre* pour éviter la collision. Ces éléments valent pour les interactions non critiques. Nous pouvons ordonner les classes d'événements décrits dans la figure 2.2, sur une échelle de sévérité, des plus sévères vers les moins sévères : les accidents, les quasi-accidents, les interactions critiques (autres que les accidents ou les quasi-accidents), les interactions non-critiques, les mobiles isolés. Différentes hypothèses, définitions opérationnelles de la sévérité, résultent en des hiérarchies différentes, qui doivent cependant rester logiques et cohérentes avec la hiérarchie de sécurité.

2. Lors de l'extrapolation des trajectoires, le mobile occupe toute l'aire de danger.

2.2.3 Le risque

Nous avons présenté un cadre général de description des interactions entre usagers, et de leur relation à la sécurité, i.e. à des collisions potentielles. Nous abordons maintenant les conséquences pour l'utilisateur, i.e. les dommages possibles pour lui, et définissons la notion de *risque*. Le risque comporte en plus de la notion de proximité à l'accident introduite plus haut, une mesure de la gravité de l'accident potentiel. Nous sommes intéressés par sa définition objective, par opposition aux aspects subjectifs que nous présentons tout de suite.

Point de vue subjectif

Il existe de nombreux modèles décrivant le comportement des usagers en situation de conduite. Ils s'opposent sur différents points, mais font tous intervenir une notion de risque subjectif et de représentation du risque. L'utilisateur en déplacement évalue de façon personnelle chaque situation, et est prêt selon différents facteurs à prendre ou ne pas prendre des risques, c'est à dire à se comporter de telle sorte qu'il augmente les probabilités de se retrouver impliqué dans un accident ou pas (par exemple selon son respect du code de la route), ainsi que les dommages d'une collision potentielle (par exemple avec le port de la ceinture de sécurité) : c'est la notion d'*acceptation du risque*.

De nombreux travaux étudient la perception du risque par les usagers (cf par exemple (Reichardt, 1992; Saad et Dionisio, 1999)). Les sentiments de l'utilisateur, comme la *gêne*, peuvent être mis en évidence grâce à des entretiens avec l'utilisateur. Ces sentiments sont présents dans de nombreuses situations, mais des usagers dans une même situation peuvent ne pas ressentir la même chose. Il n'y a pas non plus de lien direct entre la perception qu'a un usager de sa sécurité dans une situation de trafic donnée et la proximité de cette situation à l'accident. Il suffit de penser aux accidents dans lesquels les usagers impliqués ne se perçoivent pas jusqu'à la collision. Plus la circulation est fluide, rapide, donc risquée³, moins l'utilisateur ressent de gêne en général. Par contre, dans une situation congestionnée, la gêne sera généralement très importante, alors que la sécurité est très bonne. Puisqu'il est fondé sur ces perceptions, le comportement des usagers, i.e. la façon dont ils agissent et réagissent, peut varier beaucoup d'un usager à un autre dans une situation donnée. La relation entre les sentiments des usagers, leur comportement et la sécurité est complexe, voire contradictoire.

Point de vue objectif

Notre définition objective de la sécurité, i.e. l'absence d'accident, est fondée sur l'observation des interactions dans le trafic, et ne prend pas en compte les aspects subjectifs du comportement et les sentiments des usagers. La notion de risque, utilisée dans de nombreux modes de transport (routier, aérien, urbain) est classiquement constituée de

3. La vitesse est un facteur d'accident et d'aggravation des dommages bien connu (Svensson, 1998).

deux termes : une probabilité d'accident et les conséquences de l'accident. Il est indispensable de prendre en compte les conséquences de l'accident dans le risque. Par exemple, le risque n'est pas le même dans le cas d'un jeu de dés, où il y a une chance sur six de sortir le bon numéro, et dans le cas de la roulette russe, où il y a une chance sur six de perdre la vie. (Muhlrاد, 1988) cite les éléments principaux qui influent sur la gravité d'une collision :

- le type d'usagers impliqués : les usagers vulnérables sont plus susceptibles d'être blessés, et plus durement que les autres usagers à accident similaire. A l'inverse, les poids-lourds ou autobus tendent à induire des dégats plus importants chez l'autre impliqué.
- l'angle de collision : des collisions latérales, arrières ou frontales entraînent des accidents plus ou moins graves,
- les vitesses pratiquées : la vitesse est un des facteurs d'aggravation des conséquences de la collision,
- le type d'aménagement au lieu de la collision : les carrefours à feux ou sans feux présentent des profils d'accidents corporels très différents.

Formellement, dans les domaines des statistiques et de l'assurance, le risque d'accident est défini comme une espérance mathématique d'une fonction, l'utilité, des conséquences de l'accident⁴ (Haight, 1986). Reprenons l'exemple du jeu de dé. Supposons que le gain est quatre fois la mise si le 6 sort, et que la mise est perdue sinon. Le risque de ce jeu est l'espérance de gain, soit pour une mise de un euro, une perte de $(-1) \times 5/6 + 4 \times 1/6 = -1/6$ soit environ 17 centimes d'euro.

Si nous considérons un type d'accident de gravité fixée, le risque pour une interaction donnée est défini de la façon suivante,

$$\text{Risque}(\text{interaction}) = \text{Probabilité}(\text{accident}|\text{interaction}) \times \text{Gravité}(\text{accident})$$

$$\text{Risque}(\text{interaction}) = \text{Sévérité}(\text{interaction}) \times \text{Gravité}(\text{accident})$$

Pour obtenir le risque d'accident général pour une interaction, il faut agréger ce risque sur tous les types d'accident potentiel de gravités différentes. S'il existe au moins un type d'accident tel qu'une interaction peut se conclure par cet accident, son risque d'accident existe et l'interaction peut mener à l'accident. Enfin, le risque pour un lieu et une période donnés est obtenu en agrégeant le risque d'accident sur toutes les interactions qui se déroulent dans cet espace-temps et peuvent mener à un accident, soit une espérance de la gravité des accidents potentiels (Hakkert et Braimaister, 2002). Le risque peut alors être évalué à partir de l'observation du trafic comme la somme des risques d'accident de chaque interaction observée, calculé dans la plupart des études de sécurité comme un simple produit de la probabilité d'accident, i.e. la sévérité, avec la gravité d'un accident potentiel (de Leur et Sayed, 2002).

4. Notre définition formelle correspond au risque moyen de (Desroches *et al.*, 2003), défini dans la phrase suivante : "le produit de la probabilité par la gravité (en fait l'intégrale de la courbe) est un scalaire représentant le risque moyen ou l'espérance mathématique de la perte".

2.3 Les méthodes de diagnostic de sécurité

Nous avons décrit le trafic dans une perspective de sécurité. Nous allons maintenant aborder les méthodes existantes de diagnostic de la sécurité. Il faut garder à l'esprit que leur finalité est d'entreprendre des actions préventives pour améliorer la sécurité du trafic. Dans ce but, un diagnostic de sécurité doit mettre en lumière non seulement les principaux problèmes d'accident et les processus qui y ont mené, mais aussi des informations complémentaires guidant le choix ou la conception de mesures de sécurité appropriées. En particulier, identifier les caractéristiques déterminantes des comportements avant ou pendant le déroulement de l'accident peut fournir des pistes dans le but de modifier ces comportements.

Les études comparent le plus souvent différentes *entités*, ce terme vague recouvrant aussi bien les lieux, les groupes d'utilisateurs, avec leur dimension temporelle. Peuvent ainsi être comparés plusieurs endroits, plusieurs groupes d'utilisateurs ou l'évolution d'un même lieu dans le temps, en particulier avant et après un aménagement.

L'analyse des accidents est importante, mais un diagnostic complet ne peut s'en contenter, et requiert une approche plus large, que nous abordons maintenant au travers de la question posée en introduction : quels sont les événements pertinents à analyser pour un diagnostic de sécurité ? Nous laissons de côté les études, importantes, qui s'intéressent aussi au cadre global de la sécurité routière, arguant qu'il faut s'intéresser non seulement au comportement des usagers, mais aussi des pouvoirs publics, des constructeurs automobiles et des compagnies d'assurance (Spencehauer et Lassarre, 2003). La suite de cette partie est fondée sur les travaux de (Oppe, 1993; Muhlrads, 1993; Gettman et Head, 2003).

2.3.1 L'usage de l'exposition

Le diagnostic de sécurité prend classiquement en compte une mesure d'*exposition* concernant les entités étudiées (Fontaine, 2004). L'exposition mesure à quel point un individu, une population, est susceptible d'être impliqué dans un accident (Hakkert et Braimaister, 2002). Par exemple, un nombre élevé d'accidents dans un groupe d'utilisateurs peut être soit le signe d'une population qui prendrait des risques particuliers, soit la conséquence d'une forte exposition sur la route. Ce "risque" se calcule en général sous la forme du rapport d'un nombre d'accidents ou de victimes sur une mesure d'exposition à ce risque.

$$\text{Taux d'Accident} = \frac{\text{Nombre d'Accidents}}{\text{Exposition}}$$

L'exposition est estimée au travers de différents indicateurs, qui répondent à différents objectifs : le nombre d'habitants d'un pays, le nombre de véhicules, une quantité de voyage comme un temps passé sur la route ou une distance parcourue (le nombre de véhicules-kilomètres, la consommation de carburant, la durée de conduite), un nombre de certains "incidents" ou de quasi-accidents (Spencehauer et Lassarre, 2003). Avec une

définition en terme de nombre d'interactions, le taux d'accident correspond à l'estimation de la probabilité qu'une interaction évolue en accident, i.e. la sévérité de l'interaction.

Pour se servir d'un taux d'accident, il faut prendre des précautions méthodologiques (Hauer, 2001). Il existe de nombreuses mesures d'expositions. Pour qu'un taux d'accident soit correct, il doit concerner les mêmes grandeurs. Si une exposition d'un type de mobiles est au dénominateur, le numérateur doit être le nombre de mobiles du même type impliqués dans des accidents, et non le nombre d'accidents impliquant ce type de mobile. Si l'exposition d'un type d'usagers est au dénominateur, le numérateur doit être le nombre d'usagers de ce type impliqués dans des accidents, et non le nombre d'accidents impliquant ce type d'usager.

L'usage de l'exposition a deux objectifs. D'une part, il s'agit d'égaliser les différences d'exposition au risque afin de faire des comparaisons justes entre différentes entités. D'autre part, ces différences de taux entre entités permettent d'identifier des sur-représentations, donc des facteurs de risque et des possibilités d'intervention. (Hauer, 1995) montre que ces conceptions sont injustifiées. La relation entre le nombre d'accidents et l'exposition, appelée la *fonction de performance en sécurité* (Safety Performance Function ou SPF), est rarement linéaire. Si elle n'est pas linéaire, comme le montre (Hauer *et al.*, 1988) pour des intersections, une même entité aura des taux d'accident différents pour différentes expositions et la comparaison des taux d'accident ne permet de tirer aucune conclusion (cf figure 2.3). La connaissance des fonctions de performance en sécurité est aussi importante que celle de l'exposition (cf (Ekman, 1995) pour un exemple de travaux sur les fonctions de performances en sécurité).

Le concept de sur-représentation provient d'un paradigme d'épidémiologie. Il suppose qu'en l'absence d'un possible facteur, les taux d'accident comparés seraient identiques. Pour la sécurité dans les transports, cette hypothèse n'est pas toujours juste. En particulier, la sur-représentation n'a aucun lien logique avec des raisons d'action, si elle n'est pas reliée au calcul de l'espérance des accidents, de leur réduction en nombre et en gravité. Ainsi, rien ne permet en fait de dire s'il est plus important de chercher à réduire un taux d'accident plutôt que le nombre brut d'accidents. Choisir les entités à traiter selon leur taux d'accident privilégiera généralement des entités peu significatives en terme de quantités brutes. (Hakkert et Braimaister, 2002) conclut qu'il faut préférer au taux d'accident l'espérance du nombre d'accidents à venir.

Nous retenons que des comparaisons entre entités doivent être effectuées toutes choses égales par ailleurs, en particulier par rapport à ce que recouvre généralement le terme d'exposition, comme la demande de trafic. Pour autant, il ne faut pas chercher à calculer des taux d'accident, ni d'interactions car leur évolution en fonction du trafic est a priori inconnue.

Utiliser des taux d'accident est une façon d'étudier la relation entre les éléments constituant l'exposition, des événements du trafic peu sévères, et les accidents. Avec la hiérarchie de sécurité des interactions, nous postulons l'existence de cette relation. Comme les travaux que nous venons de présenter l'indiquent, cette relation est complexe. Nous

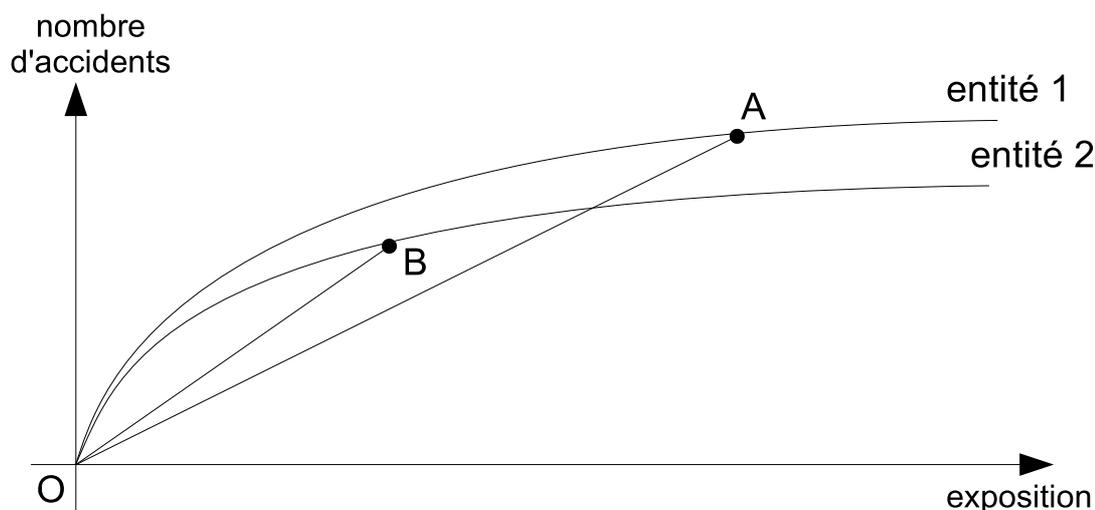


FIGURE 2.3 – Représentation des fonctions de performances en sécurité pour deux entités 1 et 2. Sur cet exemple hypothétique, l'entité 1 est moins sûre que l'entité 2 puisque pour chaque mesure d'exposition, le nombre d'accidents est plus important. Cependant, le point A de l'entité 1 correspond à un taux d'accident plus faible que celui correspondant au point B de l'entité 2 (le taux d'accident est l'angle entre l'axe des abscisses et la droite reliant A ou B à l'origine). Par exemple, si les situations 1 et 2 correspondent respectivement à un lieu avant et après aménagement, et qu'il y a eu une baisse de l'exposition du point A au point B, la variation du taux d'accident est en contradiction avec l'évolution réelle de la sécurité. L'exposition a bien changé, i.e. un usager ou un groupe d'usager est moins susceptible d'être impliqué dans un accident, mais il est impossible de conclure quant à l'évolution de la sécurité des entités.

voyons dans la suite que des méthodes permettent de mieux la comprendre et de s'en servir pour faire un diagnostic de sécurité.

2.3.2 L'analyse des accidents

La sécurité signifie l'absence d'accident. Il est donc naturel de s'intéresser aux accidents et à leurs conséquences pour étudier la sécurité du trafic. C'est la méthode traditionnelle de diagnostic de la sécurité. (Muhrad, 1993) désigne les accidents comme l'indicateur-roi de la sécurité.

Les praticiens se focalisent essentiellement sur les comptes agrégés du nombre d'accidents à l'échelle d'un pays pour la surveillance de la sécurité. Lorsque ces chiffres sont disponibles sur plusieurs années, il est alors possible d'établir des tendances et de tenter de prédire le futur.

Les approches scientifiques ont convergé vers des analyses multi-factorielles des accidents, considérés comme la conjonction de différents facteurs. Un *facteur* est classiquement défini comme "une circonstance liée à un accident de la route sans lequel l'accident n'aurait pas eu lieu... Chaque facteur est nécessaire, mais pas suffisant en lui-même pour causer un accident" (Baker et Ross, 1961), cité dans (Fleury et Brenac, 2001). Ces facteurs

sont liés à la personnalité et au comportement des usagers impliqués, à la conception et à la maintenance de la route ainsi que des véhicules. Dans ce type d'approche, les facteurs sont identifiables a posteriori, pourvu que l'accident ait été bien observé.

C'est dans l'impossibilité d'observer directement l'accident et donc l'obligation de le reconstituer a posteriori que se trouve une des principales difficultés de ces travaux. Les fichiers nationaux de relevé des accidents sont les sources classiques d'information. En France, lors d'un accident de la circulation routière, les forces de l'ordre se rendent sur les lieux de l'accident afin d'établir un procès-verbal (PV) d'accident, qui sert de base à la procédure judiciaire ultérieure (Gourlet, 2004). Parallèlement chaque accident corporel donne lieu à l'établissement, toujours par les forces de l'ordre, d'un Bulletin d'Analyse des Accident Corporels (BAAC) de la circulation routière. Une autre source classique d'information est constituée par les fichiers des compagnies d'assurance.

Analyses statistiques

Dans le cadre de mesures à l'échelle nationale ou plus limitée comme le traitement de points noirs, ces données statistiques permettent d'identifier le problème, en terme de tailles (nombre d'accidents, victimes, coût estimés pour la société), de populations touchées (types d'usager), de lieux et de situations dangereuses... Ces travaux s'appuient sur des analyses statistiques agrégées des accidents et de leurs conséquences (Muhlrad, 1993).

(Gettman et Head, 2003) indique quelques méthodes statistiques d'analyse des accidents. Suivant leur définition de la sécurité comme l'espérance du nombre d'accidents par type, par unité de temps, estimer la sécurité d'un lieu revient à construire un modèle de prédiction des accidents. Un tel modèle relie le nombre d'accidents ou le taux d'accident à des variables de trafic, comme le débit, la concentration, le rapport volume sur capacité, des produits de volumes antagonistes etc, via des équations de régression plus ou moins complexes, avec calibrage sur les données disponibles. Des méthodes statistiques avancées, comme des méthodes bayésiennes (Hauer *et al.*, 2002), des arbres de régression ou des méthodes de classification (Sayed *et al.*, 1995), sont utilisées pour étendre des modèles calibrés en un lieu à d'autres lieux dépourvus de données d'accident. D'autres méthodes ont été proposées pour combiner les taux d'accident ou essayer de construire un "niveau de service" en sécurité⁵.

Analyses en profondeur

Ce premier ensemble d'approches statistiques présente des limites car les sources d'information disponibles ne suffisent pas (Muhlrad, 1988). Premièrement, ces données statistiques d'accidents sont souvent incomplètes. Il est en particulier connu que certains types d'accidents, par exemple impliquant des usagers vulnérables, sont systématiquement sous-rapportés par les autorités compétentes soit parce qu'ils n'entrent pas dans

5. Le terme niveau de service renvoie à l'état de la circulation sur un réseau ou une partie, par exemple fluide, congestionné... basé sur une interprétation du diagramme fondamental du trafic débit/concentration.

les catégories habituelles, soit parce que l'événement n'ayant de conséquence que pour un usager non-assuré, il n'aura aucune suite judiciaire qui rende indispensable son enregistrement. Les fichiers et procès-verbaux déforment l'image de la sécurité. Deuxièmement, les données statistiques d'accidents sont par nature insuffisantes pour la reconstitution des processus générateurs d'insécurité et la mise en évidence des facteurs accidentogènes ayant contribué à causer des collisions ou en aggraver les conséquences. Les procès-verbaux ou les rapports d'enquêtes détaillés, quand ils sont disponibles et de bonne qualité, apportent des informations précieuses sur le déroulement de l'événement, mais ils sont le plus souvent biaisés par la priorité donnée à la recherche des responsabilités humaines et les facteurs relatifs aux véhicules et à l'environnement restent difficiles à déterminer.

Des méthodes complémentaires d'étude en profondeur, appelées aussi études détaillées d'accident (EDA), ont été développées pour remédier à ces inconvénients. Des équipes comme celle de l'unité de recherche Mécanismes d'Accident de l'INRETS analysent chaque cas d'accident individuellement, en retournant sur le site pour comprendre les dysfonctionnements à partir de l'infrastructure et du comportement observé (Fleury, 1993). Cela permet de valider les hypothèses sur les facteurs de l'accident, qui n'ont pas toujours été relevés dans les fichiers, par exemple des problèmes de visibilité, les vitesses pratiquées, les débits, les violations... Il peut être aussi nécessaire de récupérer des informations sur le site de l'accident en même temps que les services de police et médicaux. Il est ensuite possible d'identifier des scénarii d'accidents permettant de mieux comprendre leur processus et pouvant être utilisés sur le terrain par les praticiens pour des aménagements de sécurité (Fleury et Brenac, 2001).

Cependant, l'usage des études sur les accidents a encore des limitations intrinsèques. La première concerne le caractère aléatoire des accidents. Les accidents passés ne sont pas un indicateur parfait des accidents futurs, que l'on cherche à éliminer, comme le montrent les résultats dans le domaine (Gettman et Head, 2003). De plus les accidents sont des événements statistiquement rares. Pour des analyses à l'échelle locale, d'ampleur limitée, un recueil de données d'accidents en volume suffisant pour mesurer des variations de sécurité doit donc s'étaler sur de longues périodes, de l'ordre de plusieurs années, souvent incompatibles avec l'objectif de l'analyse, les contraintes propres au trafic urbain (variabilité rapide des conditions de circulation en fonction de modifications diverses du bâti, de l'équipement de voirie, de la réglementation locale...). Enfin, dans le but de produire des données suffisamment représentatives pour tirer des conclusions, de telles études en profondeur sont coûteuses.

Tous ces problèmes impliquent de s'intéresser à des méthodes basées sur d'autres situations de trafic que les accidents pour un diagnostic de sécurité. Parmi ces approches complémentaires existent les techniques des conflits de trafic, dont les objets d'étude sont les conflits de trafic, que nous définissons dans la suite.

2.3.3 Les Techniques des Conflits de Trafic

Les conflits de trafic

De nouveaux indicateurs, basés sur le relevé d'autres événements que les accidents, sont nécessaires pour un diagnostic de sécurité. (Svensson, 1998) indique les propriétés de ces événements de trafic : ils doivent être

- plus fréquents que les accidents,
- observables dans le trafic,
- corrélés aux accidents, statistiquement et causalement,
- presque des accidents.

Les événements de trafic ayant ces propriétés sont appelés les *conflits de trafic*. Les méthodes de diagnostic de sécurité qui les étudient sont les *techniques des conflits de trafic* (TCT). Une TCT est définie par l'ensemble des définitions et procédures qui permettent le recueil des données de conflits et leur utilisation en tant qu'indicateur d'insécurité. La première TCT connue a été développée en 1968 dans les laboratoires de General Motors (Perkins et Harris, 1968). Depuis, de nombreuses TCT furent développées dans plusieurs pays. Lors du premier International Traffic Conflicts Workshop en 1977 (Amundsen et Hydén, 1977), de nombreux chercheurs du domaine aboutirent à la définition suivante d'un conflit de trafic.

Définition 2.3.1 *Un conflit est une situation observable dans laquelle deux usagers ou plus s'approchent l'un de l'autre dans le temps et l'espace à un tel point que la collision est imminente si leurs mouvements restent inchangés*⁶.

Les conflits de trafic sont donc des interactions critiques, puisque les protagonistes sont sur une trajectoire de collision. Les TCT s'intéressent le plus souvent uniquement aux conflits de trafic les plus sévères, les plus proches de l'accident, qui correspondent aux quasi-accidents définis plus haut. Les TCT se différencient essentiellement sur les points suivants (Muhlrad, 1988) :

- la description opérationnelle des conflits, en particulier des plus sévères,
- l'échelle de sévérité,
- la procédure d'observation et de recueil des données,
- la procédure de traitement des données,
- les tests de validité et fiabilité.

Les composantes d'une Technique des Conflits de Trafic

Le premier élément est la *description opérationnelle d'un conflit*. Elle peut être objective ou subjective, selon que le conflit est détecté à partir d'une mesure objective ou du jugement convenablement calibré d'un observateur humain qui est alors supposé intégrer directement l'influence de tous les facteurs dans la situation conflictuelle. (Gettman et

6. "A conflict is an observational situation in which two or more road users approach each other in space and time to such an extent that a collision is imminent if their movements remain unchanged".

Head, 2003; van der Horst, 1990) présentent un grand nombre de mesures permettant de caractériser un conflit de trafic.

temps à la collision : (Time To Collision, TTC) il est défini à tout instant dans le cas d'une interaction critique. Il désigne l'espérance du temps nécessaire aux deux mobiles protagonistes pour entrer en collision en extrapolant leurs trajectoires actuelles, sous des hypothèses d'extrapolation à préciser (à vitesse ou accélération constante, et direction constante ou non). C'est une des mesures les plus utilisées dans les TCT. En général, seule sa valeur en un instant particulier est utilisée, comme le début de la première manœuvre d'évitement (aussi appelé Time to Accident, TA, dans la TCT suédoise) ou sa valeur minimale au cours de l'interaction critique TTC_{min} .

temps post-empiètement : (Post-Encroachment Time, PET) il désigne la durée entre le passage du premier mobile protagoniste au point de collision potentiel et le passage du second. A la différence du temps à la collision, le temps post-empiètement est une observation réelle et non une extrapolation de la situation à un moment donné. Il n'est cependant pas toujours défini, par exemple lorsque les protagonistes ne passent pas au point de collision potentiel, ou lorsque l'un des mobiles protagoniste s'arrête avant. Sa valeur extrapolée peut aussi être utilisée.

taux de freinage : il s'agit du freinage nécessaire pour éviter la collision. Les manœuvres d'évitement n'impliquent cependant pas toujours de freinage. (Nygard, 1999) envisage aussi d'utiliser la dérivée de l'accélération, le "jerk".

vitesse : la vitesse peut être mesurée à différents instants, pour l'un ou l'autre des mobiles, voire en combinant les vitesses des deux mobiles. La TCT suédoise utilise la vitesse du premier protagoniste à entreprendre une manœuvre d'évitement, à l'instant du début de cette manœuvre.

distance : la distance entre les mobiles impliqués peut être aussi mesurée à tout instant, et la valeur minimale sur toute l'interaction conservée pour la caractériser.

La détection d'un conflit résulte de l'observation simultanée de deux mobiles sur des trajectoires concourantes avec collision probable au point d'intersection, et d'une manœuvre d'évitement d'urgence. La définition de l'échelle de sévérité est directement liée aux modalités de détection de conflits, en particulier au seuil à partir duquel sont notés les conflits, et diffère selon les caractéristiques de l'événement citées plus haut prises en compte : instant du déclenchement, intensité, point critique ou proximité maximale entre les usagers impliqués, issue finale, ensemble de la manœuvre.

La *procédure d'observation et de recueil des données* peut aussi être objective ou subjective, selon qu'elle s'appuie sur des instruments de mesure ou sur le jugement d'observateurs humains. Si une description subjective des conflits implique une procédure d'observation subjective, une description objective peut aller de pair avec une procédure d'observation subjective, avec des observateurs suffisamment entraînés pour être capables d'estimer temps, distances et vitesses.

Une procédure objective est plus ou moins automatisée. Il n'existe pas à notre connaissance de méthode automatique de recueil des données de conflits de trafic. Différentes équipes ont fait des tentatives inabouties dans ce sens (Nygard, 1999; Andersson, 2000) ou ont commencé récemment (Veeraraghavan *et al.*, 2002; Rook, 2003; Wakabayashi et Renge, 2000). Des méthodes semies-automatiques existent, utilisant des enregistrements vidéo des scènes de trafic, et un observateur soit pour relever les trajectoires des mobiles (Odelid et Svensson, 1993; Svensson, 1998), soit pour juger les conflits. Ces méthodes semi-automatiques sont très coûteuses. Enfin, les conflits peuvent être directement détectés et enregistrés sur le terrain, selon une procédure standardisée par des enquêteurs formés.

Intervient ensuite une *procédure de traitement des données*, destinée à passer des résultats bruts d'observation des conflits à un indicateur d'insécurité. Certaines TCT intègrent directement à l'échelle de sévérité la relation probable des conflits aux accidents, et les conflits sont utilisés comme des données d'accident. D'autres TCT utilisent une matrice de conversion pour passer des conflits élémentaires à une prédiction d'accidents, avec dommages corporels en particulier.

Les *tests de validité* dépendent des usages de la TCT. Si les conflits de trafic sont utilisés de façon quantitative comme variable de substitution pour les accidents, il faut vérifier le lien entre les deux classes de situations de trafic. Cela consiste en général à comparer statistiquement les pouvoirs prédictifs des conflits et des accidents dans différents types d'environnements. Si les conflits sont utilisés comme compléments aux accidents pour leur pouvoir descripteur de situations potentiellement dangereuses, étendant les analyses en profondeur d'accident, la validité de la démarche est considérée comme acquise par construction (Hydén, 1987; Anonymous, 2005; Svensson, 1998). Enfin, des *tests de fiabilité* vérifient que les données recueillies sont comparables en nombre et en caractéristiques d'un lieu à l'autre et d'un observateur à l'autre.

Comparaison des Techniques des Conflits de Trafic

(Muhlrad, 1988) identifiait en 1988 douze TCT différentes, en Europe (Pays-Bas (van der Horst, 1990; Kruysse, 1991), Suède (Gårder, 1989; Anonymous, 2005; Hydén et Várhelyi, 2000), Royaume-Uni (Russam et Sabey, 1972) et France (Muhlrad, 1988)), aux Etats-Unis (Parker et Zegeer, 1989; Anonymous, 1996; Noyce *et al.*, 2000) et au Canada (Brown, 1991; Sayed *et al.*, 1994; Brown, 1994; Sayed, 1997; Sayed et Zein, 1999). Les TCT françaises et américaines ont une description opérationnelle subjective des conflits de trafic, et les autres une description objective. Elles ont subi depuis des fortunes diverses. L'intérêt pour les TCT a en particulier sérieusement diminué en France et les équipes formées ont été dissoutes. Des TCT se sont développées ou tout du moins ont été testées dans les pays en voie de développement (la Jordanie (Katamine et Hamarneh, 1998), les Phillipines (Muhlrad, 1993), les pays de l'ex-URSS (Antov, 1990), le Brésil (Guedes *et al.*, 1997), la Bolivie (Almqvist et Hydén, 1994)).

Si les TCT étaient très diverses à l'origine, les rencontres internationales autour de l'association de l'ICTCT, avec en particulier les conférences de calibration de Malmö⁷ et Trautenfels⁸ ont conduit à une uniformisation des TCT. Ainsi, toutes les TCT réellement applicables envoient des observateurs sur le terrain, hormis pour des travaux de recherche (Svensson, 1998), en particulier sur de nouvelles méthodes automatiques de recueil de données (Odelid et Svensson, 1993). L'observation se déroule en général à partir d'un point fixe, même si des tentatives ont eu lieu à partir d'un mobile dans le trafic. Dans tous les cas, le jugement de l'expert intervient pour la détection des conflits et l'évaluation de la sévérité, même si la définition opérationnelle des conflits est basée sur des mesures, d'où l'importance de la formation des observateurs. Les durées d'observation sont en général courtes, moins d'une journée en cumulé.

Ces TCT diffèrent essentiellement sur deux points : le seuil de détection des conflits et la construction de l'indicateur de sévérité, qui se réfère à la définition nationale de l'insécurité routière, à l'ensemble des collisions ou seulement aux accidents avec dommages corporels, voire décès. Nous travaillons sur une définition de la sécurité basée sur tous les accidents, quels que soient les dommages.

Le seuil de détection nécessite quelques discussions supplémentaires. Selon sa définition, la détection sera plus ou moins sélective, quitte à ensuite restreindre les études aux conflits les plus sévères, correspondant aux quasi-accident définis plus haut. La conférence de calibrage de Malmö de 1985, analysée dans (Hydén, 1987; van der Horst, 1990; Svensson, 1998), répond en partie à ces questions. Dix TCT y ont été testées, et il en ressort que les TCT comparées mesurent la sévérité des conflits sur une même échelle. Une fois le conflit détecté, les échelles de sévérité sont globalement en accord. Parmi les indicateurs utilisés, il apparaît que TTC_{min} mesure le mieux la sévérité. Viennent ensuite la distance minimale entre les protagonistes durant le conflit, puis le type d'usagers impliqués. Le type d'utilisateur intervient pour les TCT qui intègrent directement ce genre d'information de risque dans leur définition de la sévérité. De même, (Gettman et Head, 2003) fait le point sur de nombreuses études et indique que le temps à la collision est l'indicateur-roi de la sévérité des conflits de trafic. Viennent ensuite le PET et le taux de freinage. Les TCT basées sur une description subjective (France et USA) des conflits sont aussi bien corrélées aux autres TCT, et il est possible d'en conclure que le jugement calibré des observateurs mesure aussi implicitement le même type d'information spatio-temporelle (Svensson, 1998).

En outre, de nombreux travaux (van der Horst, 1990; Hydén, 1987; Brown, 1991; Brown, 1994), toujours lors de la conférence de Malmö, ont abouti à la valeur critique de $TTC_{min}=1,5$ secondes comme seuil entre les conflits sévères et non-sévères. Dans le cas où le PET est mesurable, une valeur critique reconnue est de 1 seconde. Ces seuils sont valables dans des zones urbaines, mais doivent être adaptés dans les zones rurales. La TCT suédoise est en accord avec ces seuils, mais préfère une définition de la sévérité

7. site urbain, Suède, 1983, 10 équipes

8. site rural, Autriche, 1985, 6 équipes

plus complexe, basée sur les deux mesures à l'instant de la première manœuvre d'évitement du temps à la collision, noté TA, et de la vitesse du protagoniste entreprenant la manœuvre.

Dernier point important pour l'intérêt des TCT, il faut étudier leurs fiabilité et validité. Tout d'abord, des observateurs humains sont-ils fiables ? Cet aspect fut aussi évalué lors de la conférence de Malmö, et (Svensson, 1998) rapporte que les estimations des mesures par les observateurs est assez fiable (par exemple, 0,05 seconde d'erreur sur le TA, 3 km/h sur la vitesse). De même pour la détection des conflits, l'erreur était de 26%. (Svensson, 1998) conclut que les observateurs humains sont capables de détecter les conflits sévères et de faire des estimations satisfaisantes de vitesse et de TA. (Brown, 1991; Brown, 1994) indique un "taux de précision" sur l'identification et l'évaluation de la sévérité des conflits de 77%. Il note aussi que la variation inter-observateurs ainsi que la dégradation de leur capacité au cours du temps sont faibles.

La validité est la capacité des conflits de trafic à décrire le phénomène qu'ils sont supposés mesurer. Tout d'abord, dans d'autres domaines comme l'industrie nucléaire, les transports aériens, domaines dans lesquels les accidents sont rares, les études de sécurité s'appuient naturellement sur l'analyse des incidents dont les causes sont similaires à celle d'accidents potentiels. Dans ces cas, l'argument de la similitude des processus menant aux accidents et conflits de trafic est suffisant pour les utiliser comme substituts aux accidents (Muhlrad, 1993). Les conflits ont cependant été aussi testés quant à leur corrélation aux accidents passés ou quant à leur capacité à estimer les accidents à venir. C'est là que les discussions sur les seuils de détection des TCT, la définition des conflits sévères, prennent leur sens. (Hydén, 1987) a montré que la définition suédoise des conflits sérieux basée sur les mesures de TA et de vitesse est satisfaisante et permet de se servir des conflits comme substituts aux accidents pour prédire les accidents futurs. Les distributions des conflits et des accidents selon leur sévérité sont logiques et semblables. Les conclusions de la validation de la TCT américaine par rapport à la prédiction des accidents sont en accord,

Les conflits de trafic produisent des estimations des taux d'accident moyen presque aussi exacts, et aussi précis, que ceux produits à partir de données historiques d'accidents.⁹ (Miglez *et al.*, 1985) cité dans (van der Horst, 1990)

(Brown, 1994) cherche à valider la TCT canadienne en comparant les conflits et les accidents passés. Il conclut à l'intérêt des conflits pour un diagnostic de sécurité détaillé, mais est confronté à des problèmes de corrélation entre les chiffres globaux. La corrélation entre chiffres de conflits et d'accidents s'améliore un peu lorsque les événements sont désagrégés par type de mouvement des protagonistes. Les travaux et l'expérience accumulée sur les différentes TCT développées et utilisées dans le monde montrent qu'il est possible d'utiliser des interactions moins sévères que les accidents pour étudier la

9. "Traffic conflicts produce estimates of average accident rates nearly as accurate, and just as precise, as those produced from historical accident data."

sécurité, et de parvenir ainsi à une meilleure compréhension des processus menant à l'accident, et des relations des événements de trafic à la sécurité.

Une Technique des Conflits de Trafic alternative

L'intérêt principal des TCT est de permettre un diagnostic de sécurité rapide (quelques jours), beaucoup plus rapide que les études basées sur les accidents. Certains phénomènes sont cependant difficiles à expliquer avec les TCT "classiques" présentées précédemment. Le travail de Å. Svensson (Svensson, 1998) étend la TCT au-delà des conflits les plus sévères, intégrant toutes les interactions critiques, et propose ainsi un cadre de description et d'analyse de la sécurité plus détaillé que les TCT classiques. Ce travail propose un cadre permettant d'expliquer le "paradoxe" du rond-point. Cette façon d'aménager les intersections a connu un grand succès depuis quelques années, car il s'y déroule statistiquement moins d'accidents avec dommages corporels que dans des carrefours à feux. Si la fréquence des accidents ne diminue pas, la fréquence des dommages corporels diminue (Robinson *et al.*, 2000). L'étude de (Jacquemart, 1998) indique que sur les sites de carrefours aménagés en ronds-points, la fréquence d'accident a baissé de 37% et le taux de dommages corporels de 51%. Or il se déroule sur les ronds-points nettement plus de conflits que sur les carrefours classiques. Cette constatation semble en contradiction avec la validité des TCT. Une première explication tient au changement de types d'interactions, qui ne sont plus transversales et donc moins dangereuses (Hydén et Várhelyi, 2000). Il n'en reste pas moins que les chiffres des conflits et des accidents ne sont pas du tout corrélés. Comment résoudre cette contradiction apparente ?

(Svensson, 1998) défend l'hypothèse de l'existence d'une hiérarchie de sécurité, mesurable sur une échelle de sévérité, hypothèse sur laquelle notre travail repose. Le trafic est alors vu comme un ensemble d'événements de sévérités différentes. Les événements pertinents pour la sécurité sont les interactions avec trajectoire de collision, les interactions critiques, et leur sévérité est décrite par leurs valeurs de TA et de vitesse, comme les autres TCT suédoises. Dans ce travail, la présence d'une manœuvre d'évitement n'est pas nécessaire pour décrire un conflit¹⁰.

Le diagnostic de sécurité s'appuie ensuite sur l'analyse de la forme de la distribution des interactions en fonction de leur sévérité. Cette forme peut être affectée par différents facteurs comme le type de mobile et de manœuvre d'évitement, les vitesses des mobiles impliqués, le débit, la conception du carrefour... Cette forme peut être utilisée pour

- décrire des différences de comportement des usagers,
- prédire la fréquence d'événements plus sévères à partir d'informations sur des événements moins sévères,
- proposer des mesures d'aménagements.

Å. Svensson recueille les données d'interactions, de conflits et d'accidents entre véhicules ou entre véhicules et piétons sur trois sites, dont deux sont équipés de feux. Les données

10. Une interaction critique sans manœuvre d'évitement conduit à l'accident.

sont comptées par type de manœuvre et d'usager entreprenant la manœuvre d'évitement. Les conclusions générales de son étude sont les suivantes. Toutes les distributions déclinent aux deux bouts, i.e. pour les interactions les plus sévères et les moins sévères relevées. La forme des distributions dans leur partie centrale, pour les interactions les plus nombreuses, diffère selon les facteurs étudiés. Pour les manœuvres tournantes, les distributions dépendent peu du type de carrefour, à feux ou non. Si les mobiles traversent le carrefour tout droit, il semble y avoir une différence selon que le carrefour est équipé de feux ou non. Le pic de la distribution pour le carrefour équipé se situe sur des interactions plus sévères, et est nettement plus étalé, que pour le carrefour non-équipé. Aucune conclusion ne peut être tirée concernant le type de mobile impliqué.

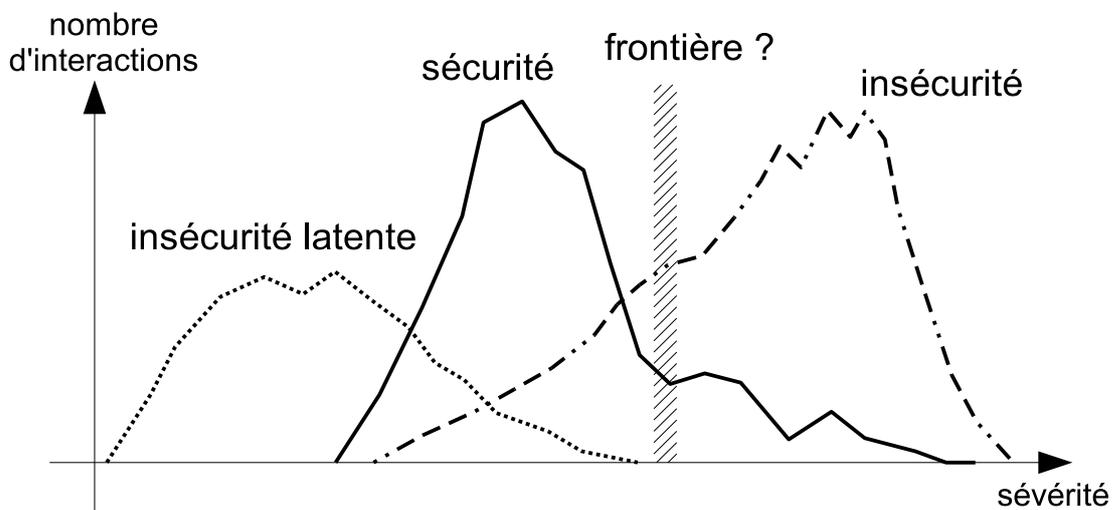


FIGURE 2.4 – Une illustration de différentes distributions d'interactions en fonction de leur sévérité, et du niveau de sécurité associé.

En conclusion, Å. Svensson postule l'existence d'une frontière dans l'échelle de sévérité au-dessus de laquelle un fort taux d'interaction est un signe d'insécurité et en-dessous de laquelle c'est un signe de sécurité (cf figure 2.4). En outre, des lieux caractérisés par un taux moyen d'interaction de sévérité faible et répartis sur de nombreux niveaux de sévérité peuvent occasionnellement produire des accidents avec dommages corporels très graves. La distribution opposée, avec un pic clair situé à des valeurs de sévérité plus grandes, mais en dessous de la frontière, semble indiquer une faible occurrence d'événements les plus sévères. Å. Svensson explique cette observation par le processus d'apprentissage des usagers (cf (Muhlrad, 1993) aussi), i.e. la meilleure vigilance des usagers habitués à être impliqués régulièrement dans des interactions de sévérité notable. Ces travaux proposent une solution au paradoxe du rond-point. Dans un rond-point, les usagers sont vigilants et bien habitués à gérer les interactions récurrentes. L'analyse de l'ensemble des interactions critiques, des plus sévères aux moins sévères, donne ainsi une image plus complète et nuancée de la sécurité.

2.3.4 Autres méthodes de sécurité

Toutes les méthodes de diagnostic de la sécurité ne s'appuient pas sur des interactions du trafic, comme les accidents et les conflits de trafic. Dans cette partie, nous détaillons d'autres éléments, certains bien particuliers aux carrefours.

Outre les accidents et les conflits de trafic, (Gettman et Head, 2003) présente un ensemble d'"autres mesures de substitution" pour évaluer la sécurité. Peuvent être relevées tout d'abord des mesures classiques d'efficacité, comme le temps d'attente, le temps de parcours, les arrêts, les origines-destinations, les temps inter-véhiculaires¹¹ (Aron *et al.*, 1994; Seddiki *et al.*, 1999), la longueur des files d'attente, les empiètements sur la ligne de feu à l'arrêt... (Gettman et Head, 2003) indique qu'aucune étude n'essaie de relier le taux d'accident à ces grandeurs. Des règles "de bons sens" sont généralement utilisées, comme "de longues files d'attente augmentent la probabilité d'accident". A la différence du recueil d'événements complexes comme les accidents ou les interactions entre mobiles, il existe des capteurs automatiques pour certaines des mesures présentées dans cette partie. Peuvent aussi être notés des éléments plus classiquement utilisés pour la sécurité comme

- la distribution des vitesses et des accélérations (moyenne et variance), en différents points, le différentiel de vitesse entre des mouvements antagonistes,
- la distribution des temps à la collision, et indicateurs dérivés (Minderhoud et Bovy, 2001; Vogel, 2003),
- les caractéristiques des points de convergence entre flux,
- la distribution des écarts acceptés pour s'insérer dans des files,
- les violations du rouge et de l'orange.

Attardons-nous un peu sur des travaux qui étudient le comportement des usagers en approche de la ligne de feu et lors de son franchissement. Ces événements peuvent être vus comme une interaction critique entre le mobile en approche et la ligne de feu considérée comme un obstacle "virtuel" (van der Horst, 1990). De nombreux travaux étudient l'impact de la variation de la longueur de certaines phases, rouges ou vertes, dans les carrefours, sur le comportement des usagers et en particulier sur le taux de violation du feu (Mahalel *et al.*, 1985; Wortman *et al.*, 1985; van der Horst et Wilmlink, 1986; van der Horst, 1988; Retting *et al.*, 2002). (van der Horst et Wilmlink, 1986) montre par exemple que l'augmentation de la durée de la phase de orange entraîne une division par deux du nombre de violations du feu. Ces travaux mettent aussi en évidence des situations de gêne chez les usagers, par exemple lorsqu'un usager viole le feu pour éviter de s'arrêter ou freiner brusquement, soumis à la pression arrière d'autres mobiles, ou après un temps d'attente jugé trop long. (Gårder, 1989) présente dans le cadre des TCT un modèle de la violation du feu rouge en fonction de paramètres caractéristiques de l'intersection.

Ces expériences permettent d'étudier le comportement de l'utilisateur par rapport à la stratégie de régulation des carrefours. Elles s'intéressent en particulier au dernier usager à franchir la ligne de feu, et au premier à s'arrêter. Une méthode classique consiste à

11. Le temps inter-véhiculaire entre deux mobiles se suivant est défini en un point comme la durée entre le passage du premier mobile et le passage du second en ce point.

représenter la probabilité de freiner en fonction de la distance à la ligne de feu, ou de la durée extrapolée pour atteindre la ligne de feu¹². (van der Horst et Wilmink, 1986) présente ainsi un décalage d'une seconde entre un système de contrôle à durées de cycle fixes, et un système de contrôle avec micro-régulation : il y a un changement dans le critère de décision utilisé par les usagers, qui prennent une décision plus tôt en approchant de la ligne de feu. Ils s'attendent à ce que le système réagisse lorsqu'ils se rapprochent de la ligne d'arrêt, c'est à dire que l'intervalle de vert se prolonge.

Ces travaux montrent que des changements mineurs dans les stratégies de régulation ont une influence réelle sur le comportement des usagers (évolution des critères de décision dans un carrefour), et sur leur sécurité, l'exemple le plus évident étant le taux de violation des feux. (Svensson, 1998) propose de mettre en relation le comportement des usagers, les marges de sécurité décrites dans certains modèles du comportement des conducteurs, avec les marges de manœuvre dans une interaction. Il n'en reste pas moins difficile d'établir une corrélation significative entre le comportement et la sécurité. Il est ainsi régulièrement constaté que les gains de sécurité attendus lors d'un aménagement donné sont rarement atteints, car les évolutions du comportement des usagers sont difficiles à prendre en compte et ignorées (Svensson, 1998).

2.4 Conclusion

Nous nous appuyons pour la suite sur les travaux des TCT suédoises, et en particulier ceux de Å. Svensson (Svensson, 1998). Parmi toutes les méthodes de diagnostic de sécurité présentées dans ce chapitre, nous préférons leur interprétation car elles sont plus détaillées et ont un pouvoir explicatif plus important. Cette approche nous semble prometteuse pour notre travail. Å. Svensson a en particulier travaillé sur les différences entre des carrefours équipés de feux de signalisation et des carrefours qui en étaient dépourvus.

Nous présentons dans la suite notre modélisation des interactions pour étudier l'impact des stratégies de régulation sur la sécurité des usagers.

12. En considérant toujours la ligne de feu comme un obstacle virtuel, ce temps extrapolé est un temps à la collision (van der Horst, 1990).

Résumé

- Les entités principales étudiées dans ce travail sont les mobiles et les carrefours, avec leur stratégie de régulation.
- Nous reprenons l'hypothèse selon laquelle le trafic est une hiérarchie de sécurité, i.e. une hiérarchie d'interactions selon leur rapport à la sécurité, i.e. l'accident. La sévérité mesure pour chaque interaction sa place dans cette hiérarchie. Elle est reliée à une probabilité d'occurrence de l'accident.
- A la notion de sévérité, s'ajoute celle de gravité de l'accident potentiel pour constituer le risque d'accident. La définition formelle du risque d'accident est l'espérance de la gravité des accidents potentiels. Pour un lieu donné, nous l'approchons en agrégeant le risque associé à chaque interaction observée, risque estimé comme le produit de la sévérité de l'interaction avec la gravité de l'accident potentiel.
- De nombreuses méthodes de diagnostic de la sécurité existent, qui tentent de comprendre les facteurs menant à l'accident. Elles étudient les accidents, de façon statistique ou approfondie, les conflits de trafic, voire toutes les interactions. Ces dernières permettent de construire une image plus détaillée de la sécurité dans un carrefour.
- Un grand nombre d'indicateurs alternatifs de sécurité existe, et tente en particulier de relier le comportement des usagers à la sécurité. Cette relation est difficile à établir.

Don't wait for accidents to happen.
Slogan de l'International Cooperation on
Theories and Concepts in Traffic safety
(ICTCT).

3

Le diagnostic de sécurité dans notre système d'analyse d'un carrefour et l'impact de stratégies de régulation

Sommaire du chapitre

3.1	Une modélisation des interactions	33
3.1.1	Quelles interactions ?	34
3.1.2	Les catégories d'interaction	35
3.1.3	Le risque et la sévérité	38
3.2	Le système expérimental	39
3.2.1	Le laboratoire Carrefour Intelligent	39
3.2.2	Le site expérimental	40
3.2.3	Les données	41
3.2.4	La base de données	44
3.3	Que détecter dans les données ?	46
3.3.1	Adaptations nécessaires	46
3.3.2	Quels indicateurs de sévérité ?	47
3.3.3	Limites et discussion	51
3.3.4	Objectifs du travail et interprétation des données	52
3.4	Conclusion	54

3.1 Une modélisation des interactions pour étudier l'impact des stratégies de régulation sur la sécurité

Nous avons vu que le trafic peut être décrit comme un ensemble d'interactions selon leur rapport à la sécurité, plus précisément une hiérarchie d'événements plus ou moins proches de l'accident. Dans cette partie, nous caractérisons les interactions pertinentes

pour étudier l'impact de stratégies de régulation sur la sécurité, et proposons une modélisation de ces interactions. Nous présentons ensuite les caractéristiques du site expérimental, de l'expérience et des données recueillies, pour le traitement desquelles il est nécessaire de faire des adaptations. La modélisation présentée ici a été présentée au 16^{ème} Workshop de l'ICTCT (Saunier *et al.*, 2003).

3.1.1 Quelles interactions ?

Nous reprenons les hypothèses de la partie 2.2.2 quant à la description du trafic comme une hiérarchie de sécurité, i.e. une hiérarchie d'interactions selon leur rapport à la sécurité, i.e. l'accident. Deux mobiles sont en interaction s'ils sont proches spatialement et que leur distance diminue (cf partie 2.2.1). La sévérité mesure pour chaque interaction sa place dans cette hiérarchie. Nous nous inspirons des travaux de Å. Svensson (Svensson, 1998) pour étudier les interactions, critiques ou non, entre mobiles, et leur sévérité, ce qui permet une interprétation détaillée de la sécurité d'un lieu comme une intersection. Pour discuter l'aspect critique des interactions, nous avons besoin d'hypothèses d'extrapolation des trajectoires. (van der Horst, 1990) étudie différentes hypothèses dans le but de calculer le temps à la collision. Nous reprenons les hypothèses classiques d'*extrapolation à vecteur-vitesse constant*, i.e. à "*vitesse et direction inchangées*", utilisées dans la TCT suédoise par exemple (Hydén, 1987; Svensson, 1998; Anonymus, 2005).

Le sujet de ce travail est la comparaison de l'impact des stratégies de régulation des feux sur le risque. Les stratégies de régulation des feux ont un impact sur le comportement général (cf chapitre précédent) et les conditions de déplacement des usagers. Dans le trafic, un mobile est impliqué dans de nombreuses interactions. Lors de la traversée d'une intersection, ses interactions avec les autres mobiles seront plus ou moins sévères. La stratégie de régulation des feux a un impact sur le déplacement des mobiles dans l'intersection, sur la façon dont les mobiles sont mis en présence, et donc sur leurs interactions, leur nombre et le risque d'accident associé. Nous étudions l'impact des stratégies de régulation sur les conditions de sécurité de la traversée d'une intersection par un mobile.

Le risque n'est pas le même dans toutes les zones fonctionnelles d'une intersection (cf figure 3.1). Lors de la traversée d'une intersection, un mobile est confronté à des interactions se déroulant en approche de la ligne de feu dans la zone de stockage, ou après son franchissement dans la zone de conflit. La zone de conflit est l'espace dans lequel des mobiles provenant de différentes origines et appartenant à des flux différents se croisent et peuvent se retrouver en présence les uns des autres. Un mobile dans la zone de conflit peut entrer en interaction avec d'autres mobiles déjà présents dans la zone de conflit. Il peut aussi entrer en interaction avec des mobiles présents dans la zone de stockage antagoniste (cf figure 3.1) s'ils sont assez proches et se rapprochent. Ces interactions avec les mobiles de la zone de stockage antagoniste ne sont pas forcément critiques. Dans un carrefour à feux, l'accès à la zone de conflit est géré par les feux de signalisation. Par le fait qu'au moins un des mobiles protagonistes est situé dans la zone de conflit, ces in-

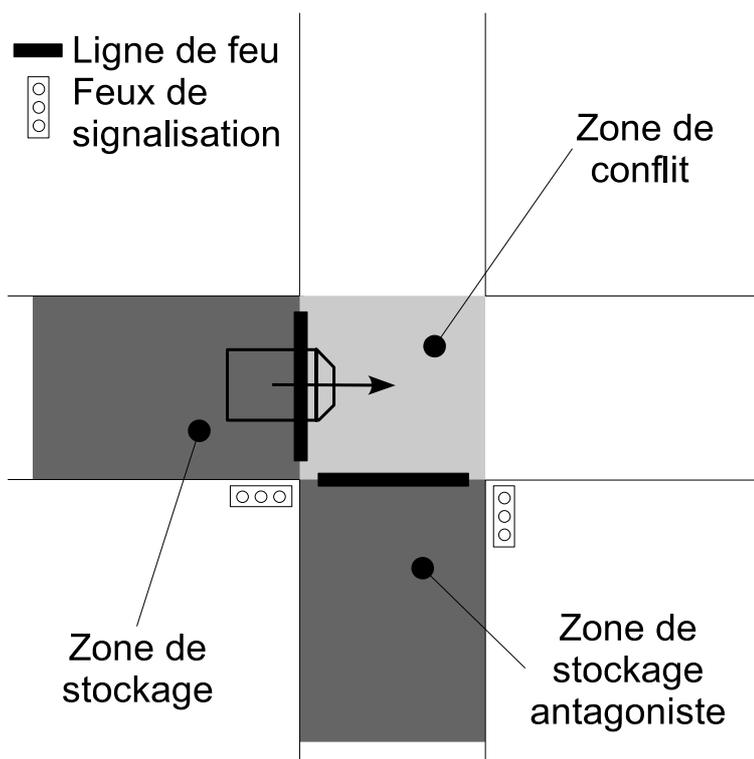


FIGURE 3.1 – Une intersection : carrefour simple de deux routes à sens unique. La zone de stockage antagoniste est définie par rapport à la zone de stockage dont provient un mobile qui entre dans la zone de conflit.

teractions, i.e. la mise en présence avec d'autres mobiles dans ou proches de la zone de conflit, ont un lien avec les feux de signalisation. C'est pourquoi nous nous intéressons particulièrement à la zone de conflit. Le recueil des interactions qui s'y déroulent doit permettre de comparer l'impact des stratégies de régulation des feux sur le risque des usagers.

Notre modélisation est fondée sur les zones fonctionnelles d'une intersection. Nous étudions l'impact des stratégies de régulation des feux sur la sécurité. Pour autant, le fait qu'une intersection soit équipée de feux de signalisation n'est pas pris en compte dans la modélisation. Les interactions telles que nous les décrivons peuvent se dérouler dans tous les types d'intersections. De même, nous ne traitons pas directement les infractions au code de la route, mais les interactions entre les mobiles, qu'il y ait ou non infraction.

3.1.2 Les catégories d'interaction

Comment décrire les interactions se déroulant dans une intersection ? De nombreuses méthodes de diagnostic de sécurité (étude des accident, TCT) catégorisent les événements auxquelles elles s'intéressent (Muhlrad, 1988; Hauer *et al.*, 1988; Cooper et Ferguson, 1976; Parker et Zegeer, 1989; Katamine et Hamarneh, 1998; Brown, 1991; Brown, 1994; Noyce *et al.*, 2000). Elles construisent des catégories selon les manœuvres des protagonistes lors du début de l'événement, plus ou moins détaillées et nombreuses. Des catégorisations

semblables pour les accidents et les conflits de trafic permettent en particulier d'essayer de valider leur relation de façon plus fine.

Pour analyser l'impact des stratégies de régulation, nous préférons étudier les conditions du franchissement de l'intersection par un mobile, i.e. les interactions dans lesquelles il est susceptible d'être impliqué selon les zones de l'intersection. Le carrefour du site expérimental est complexe et se compose de quatre intersections de deux routes à sens uniques¹. Ces quatre intersections ont une structure quasi-identique². Nous allons décrire les interactions pour une intersection, et cette description sera générique pour toutes les intersections du carrefour. Nous envisageons plus tard cette généralité pour des intersections plus complexes

Le point de départ est un mobile en approche d'une intersection. Selon sa position (amont ou aval de la ligne de feu) et les éléments avec lesquels il peut entrer en interaction (amont et aval de la ligne de feu, zone de stockage antagoniste), nous identifions quatre catégories d'interaction.

Catégorie amont seul

Un mobile en approche d'une intersection est en interaction critique avec la ligne de feu considérée comme un obstacle virtuel (cf figure 1a dans le tableau 3.1). Nous avons décrit cette approche dans la partie 2.3.4. Le comportement des usagers par rapport à l'approche et au franchissement de la ligne de feu est intéressant, en tant que tel et comme facteur explicatif des accidents se déroulant dans la zone de conflit. Ce thème, en relation avec les violations de la ligne de feu, est déjà étudié dans un autre projet sur notre site expérimental (Midenet, 1998) et nous ne travaillons pas sur cette catégorie. Les suivantes comprennent deux mobiles protagonistes.

Catégorie amont

Un mobile en approche d'une intersection peut entrer en interaction avec un autre mobile *situé en amont de la zone de conflit* (cf figure 1b dans le tableau 3.1). Par exemple, il suffit que deux mobiles se suivent et que le second ait une vitesse plus rapide que le premier pour qu'ils soient sur une trajectoire de collision.

Catégorie aval

Lorsqu'un mobile approche de la ligne de feu et entre dans la zone de conflit, il peut entrer en interaction avec un mobile *situé dans la zone de conflit*, à l'arrêt (cf figure 2a dans le tableau 3.1) ou en mouvement (cf figure 2b dans le tableau 3.1). En particulier, des interactions de type aval à l'arrêt sont observées lorsque des mobiles sont entrés dans la zone de conflit à une phase et n'ont pas pu l'évacuer avant la phase suivante et

1. La figure 2.1 représentait une telle intersection.

2. Une des sous-intersections n'a qu'une seule sortie. L'analyse reste sensiblement la même que pour les autres intersections.

l'entrée des mobiles du courant antagoniste. L'occurrence de telles interactions est liée à la stratégie de régulation.

Catégorie antagoniste

Lorsqu'un mobile entre dans la zone de conflit, il peut entrer en interaction avec un mobile *situé dans la zone de stockage antagoniste*, i.e. la zone de stockage origine du courant antagoniste. Si le mobile dans la zone de stockage antagoniste est en mouvement, il s'agit de la catégorie antagoniste en mouvement (cf figure 3a dans le tableau 3.1). Sinon l'interaction est de la catégorie antagoniste à l'arrêt (cf figure 3b dans le tableau 3.1). Les interactions de la catégorie antagoniste à l'arrêt sont prises en compte car nous considérons qu'elles ne sont pas neutres par rapport au risque d'accident. Le mobile dans la zone de stockage antagoniste est susceptible de démarrer, et nous voulons différencier l'ensemble des interactions de la catégorie antagoniste de celles dans lesquelles la zone de stockage antagoniste est vide. Pour autant, une interaction de la catégorie antagoniste à l'arrêt ne sera jamais critique selon les hypothèses d'extrapolation à vitesse constante.

Il y a une continuité entre les deux sous-catégories antagonistes. Si le mobile en déplacement dans la zone de conflit est lent, il est courant que le mobile protagoniste en mouvement dans la zone de conflit antagoniste s'arrête alors que le premier est encore dans la zone de conflit, et ainsi l'interaction change de catégorie.

Discussion

En ce qui concerne une intersection simple de deux routes à sens uniques, notre catégorisation couvre toutes les interactions entre deux mobiles situés dans ou en amont de la zone de conflit, qui respectent le sens de circulation (cf tableau 3.1). Comme nous l'avons annoncé, nous nous concentrons sur les interactions pour lesquelles au moins un des mobiles impliqués se situe dans la zone de conflit, soit les interactions des catégories aval et antagoniste. Les catégories regroupent des interactions au sens large, critiques ou non (les interactions de la catégorie antagoniste à l'arrêt ne sont pas critiques). Bien que différentes et moins détaillées par rapport aux manœuvres des mobiles, les catégories de notre approche fondée sur les zones d'une intersection sont cohérentes avec les catégories des méthodes classiques citées plus haut. Par exemple, parmi les quinze catégories classiques présentées par (Hauer, 1980), il n'en reste que huit dans une intersection de deux routes à sens unique, et aucune de ces huit catégories ne se retrouve partagée entre deux de nos catégories.

La remarque sur la continuité des deux sous-catégories de la catégorie antagoniste valent pour toutes les catégories présentées. Leurs frontières doivent être précisées. Où placer les limites physiques exactes de la zone de conflit ? Quand un mobile est-il considéré dans la zone de conflit ? S'il passe les roues avant ? Les quatre roues ? Ces éléments doivent être décrits précisément pour que ces catégories soient opérationnelles, par exem-

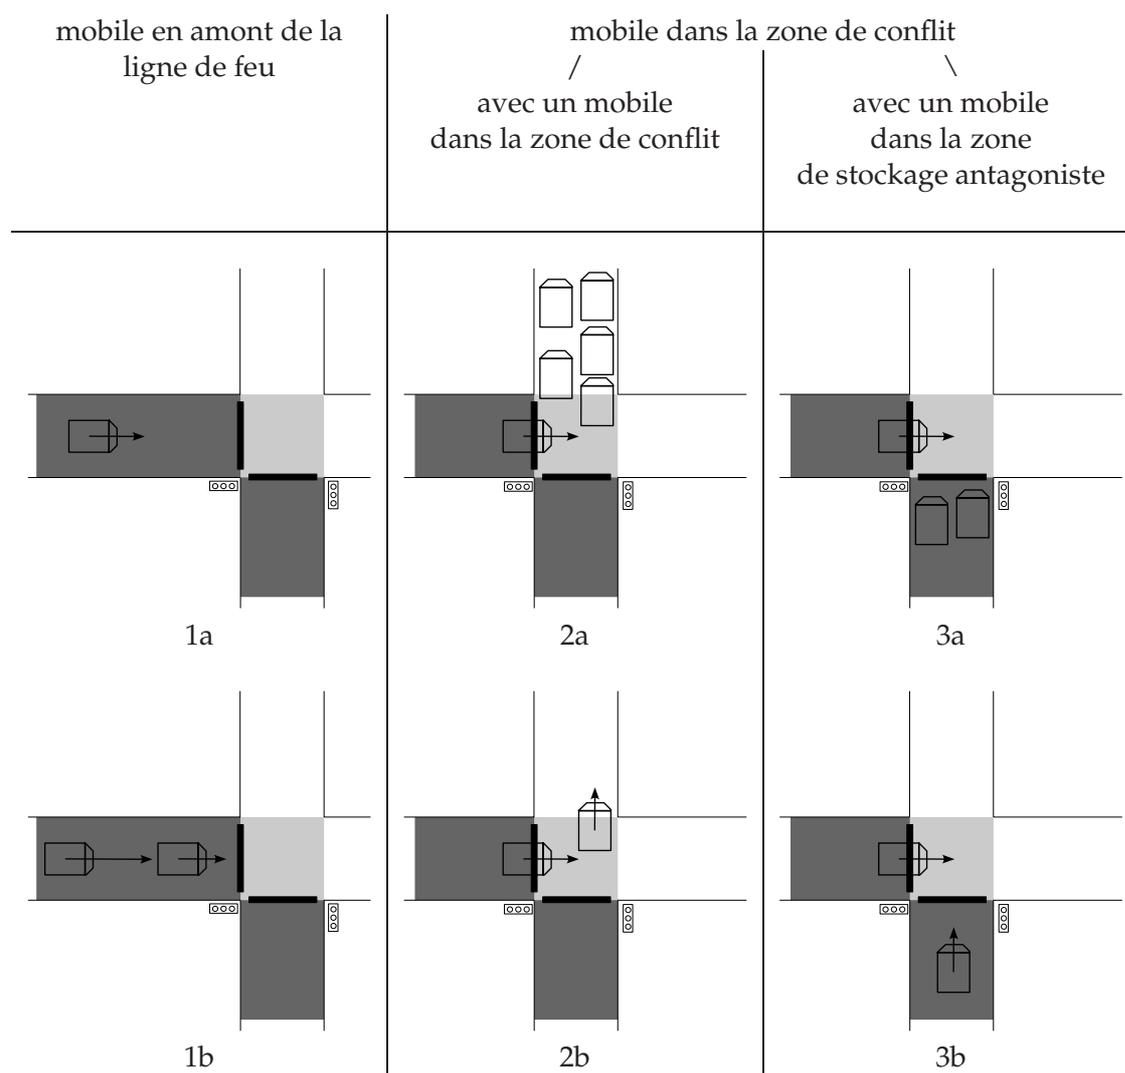


TABLE 3.1 – Les catégories d’interactions dans une intersection.

ple pour des observateurs humains sur le terrain. Pour notre travail, nous définissons ces limites en fonction des données.

Dans le cas d’intersections plus complexes, comme des intersections de routes à double sens ou de plus de deux routes, il est possible de généraliser l’approche consistant à suivre un mobile pendant sa traversée de l’intersection. Les types d’interactions possibles sur ces intersections plus complexes sont plus nombreuses. Les routes à double sens introduisent par exemple les interactions d’un mobile avec un autre venant d’en face, tournant à gauche. Nous y revenons plus tard.

3.1.3 Le risque et la sévérité

Il faut maintenant faire le lien entre ces interactions et le risque d’accident. Pour un lieu donné, nous l’approchons en agrégeant le risque associé à chaque interaction observée, risque estimé comme le produit de la sévérité de l’interaction avec la gravité de

l'accident potentiel. Le risque pour une stratégie de régulation d'un carrefour est le risque pour ce carrefour pendant que la stratégie est appliquée.

La gravité n'est cependant pas accessible dans nos données. Nous quantifions donc la sévérité des interactions étudiées, qui s'évalue comme la distance dans le temps et l'espace entre les mobiles impliqués, que l'interaction soit critique ou non. Nous avons présenté dans le chapitre précédent différents indicateurs de sévérité de la littérature, simples comme des vitesses ou des distances, et plus élaborés pour les interactions présentant une trajectoire de collision comme le temps à la collision (Time To Collision) et le temps post-empiètement (Post-Encroachment Time). Les indicateurs utilisés dans ce travail sont définis en fonction des caractéristiques des données traitées.

Nous évaluons donc l'impact d'une stratégie de régulation sur les interactions des catégories aval et antagonistes, leur nombre, et leur sévérité. Nous avons vu dans le chapitre précédent que la validation du lien entre les accidents et les interactions de différentes sévérités, dont les conflits de trafic, est difficile. Nous nous appuyons sur les travaux de Å. Svensson pour interpréter la distribution des interactions selon leur sévérité, ce qui offre une image de la sécurité plus détaillée que des études basées sur les interactions de sévérité donnée, comme les accidents ou les quasi-accidents. Ces travaux montrent que l'ensemble des interactions et pas seulement les plus sévères, a un lien à l'accident, et permet d'évaluer la sécurité d'une intersection. A notre connaissance, l'influence relative de différentes stratégies de régulation sur les interactions et leur sévérité n'a jamais été étudiée.

3.2 Le système expérimental

3.2.1 Le laboratoire Carrefour Intelligent

Notre travail s'appuie sur un dispositif expérimental d'observation automatique d'un carrefour réel, dans le cadre du laboratoire Carrefour Intelligent (CI) développé à l'INRETS depuis de nombreuses années (Boillot, 2002a; Boillot, 2002b; Midenet, 2002). Nous allons décrire dans cette partie le site expérimental, les données fournies par les capteurs, et la base de données issue de l'application de différentes stratégies de régulation sur le site pendant 8 mois.

Le projet CI vise à construire une modélisation du fonctionnement dynamique d'un carrefour à feux, une architecture informatique de commande de feux et de surveillance du fonctionnement d'un carrefour urbain. Le laboratoire est alimenté en temps réel par les mesures issues de plusieurs capteurs surveillant les abords et le centre d'un carrefour réel. Les fonctions du laboratoire CI sont les suivantes :

- une régulation adaptative des feux (système CRONOS, décrit dans la partie 2.1.3),
- une surveillance en continu du carrefour : récupération d'indicateurs de trafic, détection des incidents (DAI) et reconstitution de l'écoulement du trafic au niveau des mouvements directionnels, les origines-destinations des mobiles,
- le diagnostic multi-critère du carrefour : impact sur l'environnement, la sécurité.

Ces fonctions impliquent le développement d'outils et de méthodes spécifiques à la gestion du trafic urbain au niveau des carrefours à feux, dans les domaines du génie logiciel (architecture multi-plateforme, communication hardware / software), du traitement de l'image, et de l'Intelligence Artificielle (interprétation des données, classification, apprentissage). Le système que nous construisons pour répondre à notre problématique utilise les mêmes informations que les autres systèmes développés dans le cadre du laboratoire CI.

3.2.2 Le site expérimental

Le carrefour réel étudié est un carrefour à feux complexe situé dans une région urbaine près de Paris, dans le département du Val de Marne (cf figure 3.2). Deux routes se croisent en ce carrefour. Les débits constatés sur ces deux routes sont très différents :

- un axe principal "Paris-Banlieue" relié à l'autoroute A6, à fort trafic,
- un axe secondaire reliant deux villes du Val de Marne, Arcueil et le Kremlin-Bicêtre, à trafic local moins soutenu.

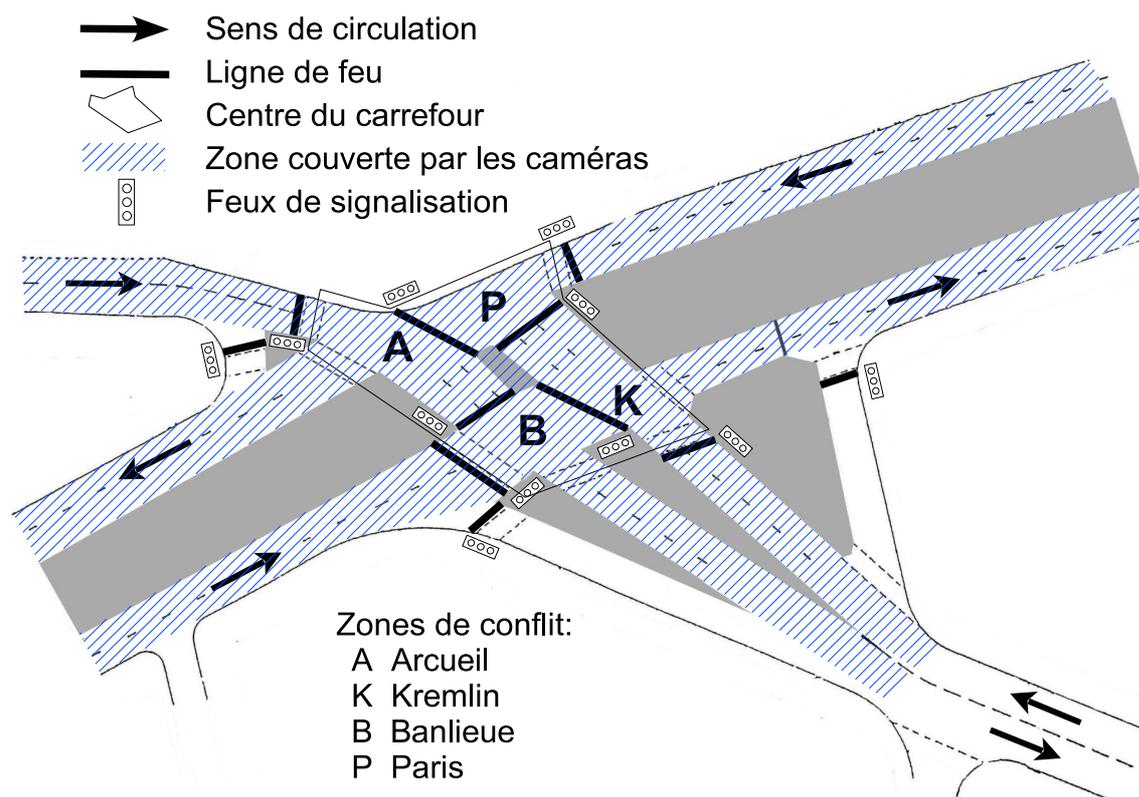


FIGURE 3.2 – Site expérimental : plan du carrefour équipé.

Le carrefour est considéré comme isolé car les carrefours à feux les plus proches sont à environ 500 mètres. Ce carrefour complexe peut se décomposer en quatre sous-carrefours simples de routes à sens unique, que nous appelons intersections (cf figure 2.1). Nous les nommons selon l'origine du tronçon d'entrée sur le carrefour. Quatre *tronçons* mènent

au carrefour, i.e. aux quatre zones de conflit, et trois tronçons en partent³ ; ils sont tous à sens unique. Le *centre* du carrefour est composé de quatre zones de conflit et quatre zones de stockage pour les mobiles tournant à gauche après avoir déjà traversé une zone de conflit. Onze feux pour les véhicules équipent le carrefour.

Les mouvements de tourne-à-gauche sont contrôlés par des feux. Les mouvements de tourne-à-droite sont interdits dans le carrefour. Trois bretelles en amont permettent d'effectuer ces mouvements avant d'entrer sur le carrefour. Ce carrefour est équipé de huit caméras vidéo fixes disposées en hauteur, couvrant la partie intérieure du carrefour et les approches.

3.2.3 Les données

Le laboratoire CI dispose essentiellement de capteurs vidéo pour observer ce carrefour, et, en complément, de quelques boucles électromagnétiques sur les entrées pour mesurer les débits. Les états des feux sont aussi transmis au laboratoire chaque seconde. L'utilisation de capteurs vidéo pour observer le trafic est encore assez rare en Europe, en particulier en milieu urbain. Les capteurs les plus couramment utilisés pour l'observation du trafic sont les boucles électromagnétiques (Cohen, 1993). Outre leur faible précision, elles fournissent seulement une information ponctuelle sur une route, par opposition aux caméras vidéo qui permettent de couvrir une certaine surface, et donc d'accéder à des caractéristiques spatiales comme la concentration, la longueur des files d'attente, les mouvements... A ce dispositif s'ajoutent des moyens d'enregistrement complets (mesures, états des feux à la seconde, films vidéo).

Les données vidéo, numérisées, sont analysées par un outil de traitement de l'image, développé à l'INRETS et commercialisé par la société CITILOG⁴, conçu pour fonctionner 24 heures par jour, dans toutes les conditions météorologiques (cf (Le Cerf, 1999) pour plus d'informations et des références). Les données obtenues sont des "images" bidimensionnelles discrètes de l'occupation du carrefour⁵. L'unité d'information, le "pixel" de ces "images", est appelée le *pavé*. L'état brut d'un pavé, à la sortie du traitement d'image, est calculé plusieurs fois par seconde et peut prendre 3 valeurs : "vide", "présence de mobiles en mouvement", "présence de mobiles à l'arrêt". Ces informations sont agrégées temporellement sur une seconde en 6 états (cf tableau 3.2) : Vide, Trace de présence, Début de présence, Fin de présence, Présence en mouvement, Présence à l'arrêt. Ces six modalités permettent une bonne représentation de la dynamique des déplacements (Midenet, 1998).

Grâce à des hypothèses sur les déplacements des mobiles, le traitement d'image fournit une information linéaire sur les tronçons d'entrée et de sortie. Il n'est par contre pas possible de faire ce type d'hypothèses au centre du carrefour, où l'information est donc bidi-

3. Une des sous-intersections (P) ne mène qu'à une autre sous-intersection (cf figure 3.2). Il n'y a que 3 tronçons de sortie du carrefour. Nous verrons que l'analyse reste sensiblement la même que pour les autres intersections.

4. <http://www.citilog.com>

5. Le traitement d'image reconstitue aussi les files d'attente des mobiles sur les lignes de feux.

Etat du pavé	instant $t - 1$	entre $t - 1$ et t	instant t
Vide	V	V	V
Trace de présence	V	O	V
Début de présence	V	V ou O ou A	O
Fin de présence	O	V ou O ou A	V
Présence en mouvement	O ou A	V ou O ou A	O
Présence en arrêt	O ou A	V ou O ou A	A

TABLE 3.2 – Description des valeurs possibles de l'état des pavés, à partir des états bruts calculés par le traitement d'image (plusieurs fois par seconde), à l'instant t , la seconde précédente $t - 1$ et entre-temps : vide (V), occupé (O), occupé en arrêt (A).

mensionnelle. Les pavés indiquent la présence de mobiles sur la période d'une seconde, donc apportent des informations sur les positions des mobiles, mais aussi sur leur dynamique pendant cette seconde (apparition, disparition, passage rapide). Cela nous permet d'avoir accès aux mouvements des mobiles, d'une façon robuste. C'est le *niveau de description* des données le plus fin disponible. Ce niveau de description a déjà été utilisé dans des travaux du laboratoire CI (Midenet, 1998; Le Cerf, 1999). La figure 3.3 représente une *image* du carrefour au niveau de description des pavés. Les pavés y sont regroupés par zone fonctionnelle du carrefour.

Les autres fonctions du laboratoire CI utilisent ces données à un niveau plus agrégé spatialement, celui des zones fonctionnelles du carrefour, i.e. les tronçons d'une part, les zones de stockage et de conflit du centre du carrefour d'autre part. Ces données sont des informations mesurées au niveau de la zone, sans chercher à interpréter les configurations des pavés. Par exemple, la stratégie adaptative CRONOS utilise des taux d'occupation et d'arrêt pour la zone, ainsi que les files d'attente sur les tronçons d'entrée. La figure 3.4 montre un schéma du carrefour au niveau de description des zones.

Les données qui viennent d'être présentées ont certaines caractéristiques, et des limitations. Leur définition spatio-temporelle maximale est supérieure à ce qui existe, mais faible pour interpréter des mouvements de mobiles. Le traitement d'image donne des images robustes au niveau des zones (conditions d'éclairage, météorologiques...), mais des images très bruitées au niveau des pavés. Il faut compter avec la hauteur des mobiles et la perspective, cause de masquage d'autres mobiles et de détections injustifiées de présence. Les pavés indiquent des informations de présence, mais n'identifient absolument pas le mobile. Le capot d'une voiture, la roue d'une moto, un piéton, un sac poussé par le vent, le reflet des phares sur la chaussée mouillée..., pourront tous être détectés comme de la présence. Les données au niveau des pavés ne contiennent ainsi aucune information sur le type de mobile détecté, et ne permettent pas de faire facilement un suivi des mobiles. Les mobiles ne sont pas reconnus individuellement. Sont connus les pavés occupés à un instant t , puis à l'instant $t + 1$, etc, sans lien entre les instants. Des tentatives ont déjà eu lieu pour reconstruire les déplacements des mobiles (Le Cerf, 1999). Nous n'avons pas cherché à poursuivre dans cette voie.

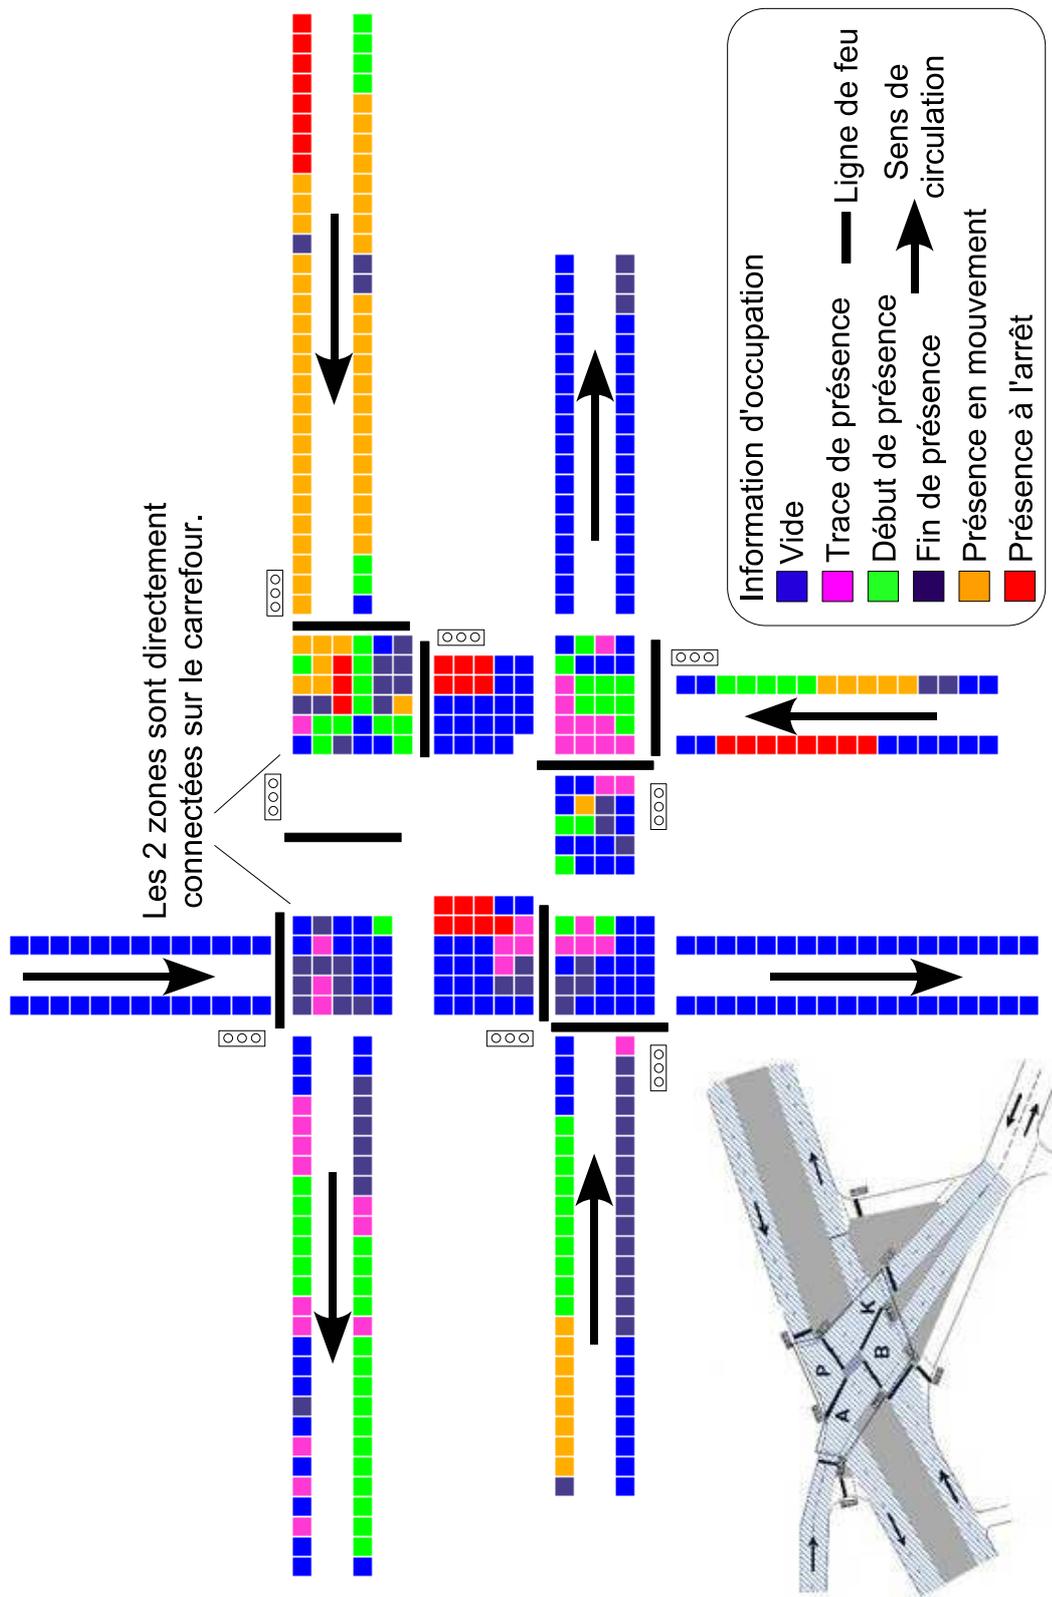


FIGURE 3.3 – Une image du carrefour au niveau de description le plus fin. La zone de conflit ne disposant pas de tronçon de sortie du carrefour n'est pas distinguée de la seule zone de stockage aval.

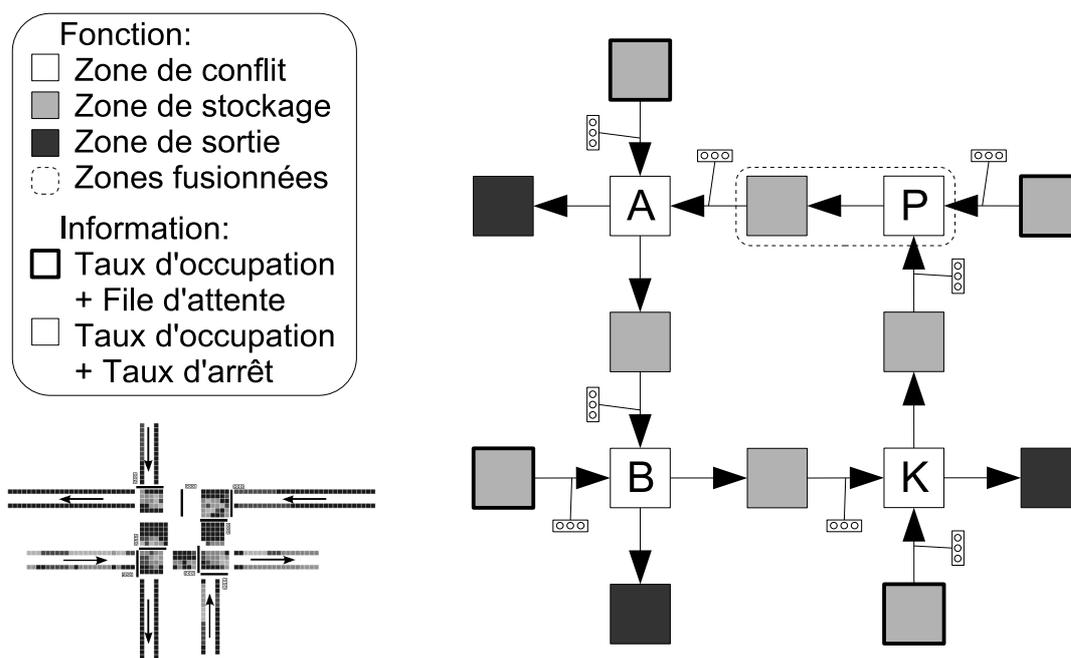


FIGURE 3.4 – Schéma du carrefour au niveau de description des zones, obtenu par agrégation spatiale des pavés de chaque zone fonctionnelle du carrefour. Les informations indiquées sont celles qui alimentent CRONOS.

Les données au niveau des zones sont cependant très robustes, puisque de nombreuses applications du laboratoire CI les utilisent avec succès. Ceci indique bien qu'il est possible de tirer des informations fiables et robustes des pavés. Un autre atout est la polyvalence de ces données, qui sont exploitées pour des applications diverses dans un système unifié. Ainsi, notre travail ne consiste pas à améliorer les capteurs ou le traitement d'image. Notre approche est compatible avec tous les capteurs en mesure de fournir une information d'occupation surfacique des carrefours.

Pour résumer, les données dont nous disposons sont des images d'occupation du carrefour, disponibles chaque seconde à deux niveaux de description différents, celui des pavés, plus fin spatialement mais aussi plus bruité, et celui des zones, plus robuste, mais moins précis.

3.2.4 La base de données

Sur le site réel décrit précédemment a été conduite une expérience grandeur nature sur une période de huit mois consécutifs, entre juillet 1998 et février 1999, pendant laquelle différentes stratégies de régulation ont été appliquées sur le terrain par demi-journées complètes. En particulier, la stratégie de régulation adaptative CRONOS a été comparée à une stratégie classique dite de Référence, de type micro-régulation, développée et mise en place par les exploitants de la voirie, la Direction Départementale de l'Équipement (DDE) du Val de Marne. Il s'agit d'une commande de type micro-régulation, basée sur un plan de feux avec prolongement possible des phases de vert en fonction du trafic dé-

tecté par les boucles électromagnétiques disposées sur les tronçons d'entrée. La longueur de ses cycles est donc variable. Le plan d'expérience prévoyait une alternance pseudo-aléatoire des stratégies sur une longue période, pour garantir des conditions homogènes et comparables. Ces conditions expérimentales excluent l'étude des effets à long terme des commandes.

Toutes les données ont été enregistrées, i.e. les données au niveau des pavés, les états des feux, les données de trafic fournies par les boucles, et les enregistrements vidéo bruts des scènes de trafic par les huit capteurs vidéo. Il est ainsi possible de rejouer de façon très complète les scènes de trafic, en synchronisant les bandes vidéo et les données enregistrées.

A partir de l'enregistrement de ces situations ont été constitués deux ensembles d'échantillons d'observation relatifs aux deux stratégies étudiées, CRONOS et la stratégie de Référence, un échantillon correspondant à une plage fixe égale à une heure. Les périodes de dysfonctionnement du système ont été éliminées. Les échantillons retenus représentent donc les situations normales et récurrentes. Une classification des échantillons sur la base de la demande horaire de trafic pour tout le carrefour nous permet de distinguer quatre catégories ou conditions de trafic : "trafic en heure de pointe", "trafic dense", "trafic fluide", "trafic très fluide" (cf tableau 3.3 pour les effectifs de ces échantillons pour CRONOS et la stratégie de Référence). La demande totale pour tout le carrefour est estimée par un système de reconstitution des parcours entre une origine et une destination, développé dans le laboratoire CI (Midenet *et al.*, 1999; Midenet *et al.*, 2004). Enfin, il faut noter qu'aucun accident ne s'est produit sur le carrefour pendant l'expérience.

Catégorie d'échantillon	Effectif
trafic en heure de pointe	53
trafic dense	74
trafic fluide	129
trafic très fluide	34
total	290

TABLE 3.3 – Classification des échantillons horaires en quatre catégories, avec leurs effectifs, pour CRONOS et la stratégie de Référence.

Les fonctions développées dans le cadre du laboratoire CI reconstituant des indicateurs de trafic sont testées sur ces échantillons de données. Ces indicateurs sont alors reconstruits pour tous les échantillons horaires de notre base pour une catégorie de trafic donnée. Ils peuvent alors être comparés en fonction de la stratégie appliquée. Bien que les données proviennent d'un seul site, la durée exceptionnelle de la période expérimentale, ainsi que la précision des données recueillies nous permettent de comparer les effets des stratégies de régulation sur le comportement des usager et leur risque. Le protocole expérimental garantit une comparaison toutes choses égales par ailleurs : paramètres d'infrastructure, volume de trafic, conditions météorologiques...

3.3 Que détecter dans les données ?

Nous étudions dans cette partie les conséquences des caractéristiques des données sur notre modélisation et les objectifs de notre travail.

3.3.1 Adaptations nécessaires

Nous avons insisté sur l'importance de la définition des zones fonctionnelles d'une intersection pour la catégorisation des interactions. Nous utilisons directement les données du laboratoire CI, en particulier les regroupements des pavés par zone fonctionnelle (cf figure 3.4)⁶.

Les données indiquent la présence des mobiles, sans les individualiser. Il est donc impossible d'étudier les interactions entre mobiles d'un même peloton, i.e. assez proches et se déplaçant à des vitesses voisines, puisqu'ils seront détectés comme un ensemble plus ou moins homogène de présence. Nous ne pouvons pas interpréter les mouvements en termes individuels. Notre description des catégories d'interactions s'applique aussi à des groupes de mobiles. Dans la suite, nous parlons indifféremment d'un mobile ou d'un groupe de mobiles, puisque nous ne sommes pas capables de faire la différence dans les données.

De même que les interactions entre mobiles à l'intérieur d'un même peloton sont impossibles à détecter, cette tâche est difficile pour des mobiles situés dans une même zone. Nous ne cherchons donc pas à étudier les interactions entre mobiles situés dans une même zone, hormis dans un cas. L'information d'arrêt est assez fiable pour nous permettre de travailler sur les interactions entre mobiles en mouvement et mobiles à l'arrêt dans une même zone. Nous avons choisi pour notre étude les catégories d'interactions dans lesquelles au moins un protagoniste se situe dans la zone de conflit, à savoir les catégories aval et antagoniste. Les problèmes de détection à l'intérieur d'une même zone nous amènent à ne considérer que les interactions entre mobiles en mouvement dans la zone de conflit et mobiles à l'arrêt dans la zone de conflit parmi les interactions de la catégorie aval (cf figure 2a dans le tableau 3.1). Nous pouvons étudier toutes les interactions de la catégorie antagoniste (cf figures 3a et 3b dans le tableau 3.1).

Pour des raisons décrites dans le chapitre suivant, le nombre de groupes de mobiles présents dans une zone donnée ne peut être déterminé de façon fiable. Nous pouvons cependant utiliser les informations de mouvement et d'arrêt par zone. Nous détectons donc *l'existence ou pas d'interactions des catégories étudiées dans une intersection*, sans pouvoir dénombrer un nombre d'interactions.

Ces difficultés, l'absence d'individualisation et d'identification des mobiles, rendent le suivi des mobiles d'une image à l'autre complexe. Nous préférons travailler sur l'interprétation des données à chaque seconde, indépendamment des autres instants. Interpréter la dynamique des mobiles à partir d'une image est possible puisque, outre

6. La zone de conflit P est confondue avec sa zone de stockage aval, mais les zones de conflit composant le carrefour sont bien distinctes de leur zones de stockage amont respectives.

des informations de position, elle contient aussi des informations sur la dynamique, en agrégeant des informations brutes de présence sur une seconde. Un pavé dans l'état "Trace" indique par exemple un passage rapide.

Ce choix a un impact sur la façon dont nous détectons les interactions. Une interaction entre deux mobiles peut durer un certain temps. Elle commence lorsque les deux mobiles se rapprochant l'un de l'autre sont suffisamment proches. Elle dure jusqu'à ce que les deux mobiles commencent à s'éloigner l'un de l'autre. A partir des données fournies chaque seconde, nous pouvons détecter si des interactions sont en cours, mais sans pouvoir les relier à celles détectées à la seconde précédente. Une même interaction peut donc être détectée plusieurs fois. Nous mesurons alors un *nombre de secondes*, une *durée d'interaction* sur l'intersection. Plus les vitesses des mobiles en interactions seront faibles, plus leurs interactions seront détectées un grand nombre de fois. Leur sévérité, selon les indicateurs utilisés, diminue généralement avec la vitesse des mobiles. Les interactions impliquant des mobiles dont les vitesses sont faibles ne perturberont pas dans une certaine mesure les comptes d'interactions plus sévères.

Pour résumer, nous détectons à *chaque instant l'existence d'interaction des catégories étudiées*, indépendamment des autres instants.

3.3.2 Quels indicateurs de sévérité ?

Comme nous l'avons annoncé auparavant, nous ne disposons pas d'informations sur la gravité des accidents potentiels, seconde composante du risque avec la sévérité. L'information la plus importante, le type d'utilisateur impliqué, n'est pas disponible dans les données, et nous disposons de peu d'information sur les mouvements relatifs précis des mobiles impliqués dans une interaction⁷.

Nous cherchons à estimer la sévérité des interactions des catégories étudiées, i.e. la distance spatio-temporelle entre les mobiles impliqués. Les données disponibles à un instant donné comprennent des informations de distance spatiale et de vitesse. Nous pourrions alors reconstituer des indicateurs spatio-temporels classiques comme le temps à la collision. Etant donnée la définition spatio-temporelle des données, il ne nous semble cependant pas pertinent de faire des calculs sur des estimations de vitesse et de distance, et de multiplier ainsi les imprécisions.

Nous proposons deux indicateurs de sévérité pour une interaction détectée à un instant donné,

un indicateur de proximité : défini comme la distance minimale extrapolée à partir de cet instant entre les deux mobiles protagonistes (cf figure 3.5),

un indicateur de vitesse : défini comme la norme de la différence des vecteurs-vitesse des deux mobiles protagonistes à cet instant (pour un groupe de mobiles, supposé relativement homogène, son vecteurs-vitesse moyen est considéré) (cf figure 3.6).

7. Nous ne pouvons que faire des hypothèses sur les mouvements majoritaires des mobiles des catégories amont (collision potentielle arrière) et de la catégorie antagoniste (collision potentielle à angle droit).

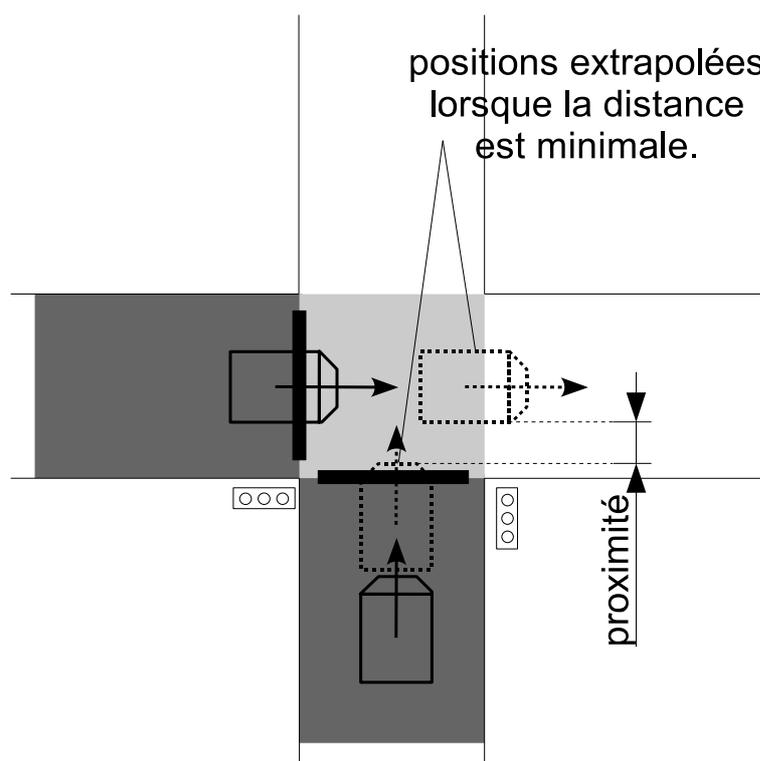


FIGURE 3.5 – Illustration de l'indicateur de proximité pour une interaction de la catégorie antagoniste en mouvement.

Ces deux indicateurs, et surtout leur conjonction, permettent de mesurer la proximité de deux protagonistes dans le temps et l'espace. Si l'indicateur de proximité entre deux mobiles en interaction a une valeur nulle, cela signifie que ces mobiles sont sur une trajectoire de collision. Une valeur non nulle de l'indicateur indique que l'interaction n'est pas critique. Plus la valeur est faible, plus les protagonistes sont proches d'une trajectoire de collision. Cette distance est choisie car elle a un lien direct au caractère critique d'une interaction, et son aspect extrapolé la rend plus robuste à la détection des interactions toutes les secondes, indépendamment des autres. Une simple distance entre les mobiles serait très aléatoire selon l'instant de détection, et aurait peu de sens.

La vitesse est un facteur majeur d'accident⁸. Le différentiel de vitesse est la vitesse de chaque mobile par rapport à l'autre, i.e. dans le référentiel de l'autre. Plus le différentiel de vitesse entre deux mobiles augmente, plus la vitesse de chaque mobile par rapport à l'autre augmente, plus leurs marges de manœuvre sont limitées, i.e. plus les distances parcourues pendant leurs temps de réaction⁹ sont grandes. Si les mobiles sont sur une trajectoire de collision, la collision est donc sûre au-delà d'une certaine valeur de l'indicateur. Dans tous les cas, l'indicateur de vitesse mesure les marges de manœuvre des mobiles. Le différentiel a les bonnes propriétés suivantes. Il est symétrique par rapport

8. "Research has shown, however, that speed is indeed a major contributory factor in accidents and should be dealt with as a topic of great importance." (Hakkert et Braimaister, 2002)

9. Le temps de réaction moyen des conducteurs est estimé entre 1 et 1.5 secondes (van der Horst et Wilmink, 1986).

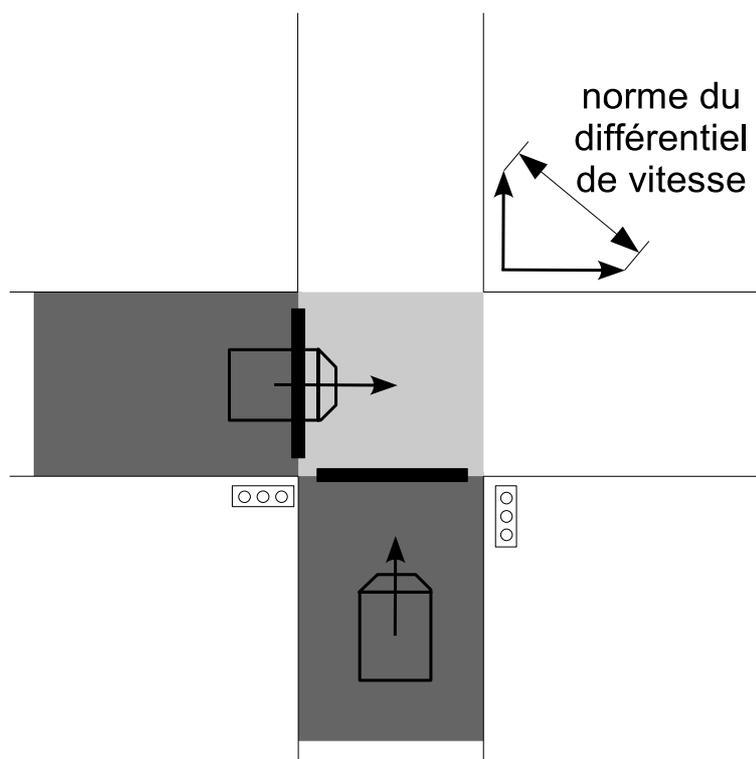


FIGURE 3.6 – Illustration de l'indicateur de vitesse pour une interaction de la catégorie antagoniste en mouvement.

aux deux mobiles. Deux mobiles se suivant à des vitesses sensiblement égales auront un indicateur de vitesse très faible, alors qu'il sera très élevé pour deux mobiles se déplaçant l'un vers l'autre. Les valeurs minimale et maximale de l'indicateur pour deux vecteurs-vitesses de norme fixée sont atteintes dans ces deux cas, respectivement pour un angle de 0° et 180° . L'indicateur de vitesse seul, sans l'indicateur de proximité, ne permet pas de mesurer la sévérité d'une interaction. Si des mobiles sont trop éloignés, leur différentiel de vitesse aura beau être très grand, l'occurrence d'une collision entre eux est très peu vraisemblable.

Plus ces deux indicateurs de sévérité augmentent, plus les protagonistes sont proches et se déplacent vite l'un par rapport à l'autre, plus ils sont donc proches dans le temps et l'espace, et donc leur interaction sévère. Nos indicateurs tirent leur validité de leur construction. Combiner ces deux dimensions en un seul indicateur de sévérité n'est pas évident. Nous ne savons pas a priori comment se comparent les deux indicateurs de sévérité. Une interaction très sévère selon l'indicateur de proximité et peu sévère selon l'indicateur de vitesse est-elle de sévérité équivalente à une interaction très sévère selon l'indicateur de vitesse et peu sévère selon l'indicateur de proximité ? De plus, une combinaison en un indicateur qui n'aurait pas de signification directe, comme la combinaison du TA et de la vitesse dans la TCT suédoise, nécessite alors de longs travaux de validation hors du champ de ce travail (Hydén, 1987). Nous ne pouvons comparer simultanément

les deux indicateurs de sévérité que lorsque les comparaisons selon chaque indicateur sont en accord.

Les rapports de sévérité entre les interactions des deux sous-catégories de la catégorie antagoniste ne sont pas simples. Les interactions de la catégorie antagoniste en mouvement sont les seules qui peuvent être critiques selon les hypothèses d'extrapolation des trajectoires. L'indicateur de proximité traduit ce fait. Pour des interactions de la catégorie antagoniste à l'arrêt, il ne peut pas avoir une valeur nulle. Dans le cas général, le mobile dans la zone de stockage traverse la zone de conflit en second. Dans ce cas, pour deux interactions de la catégorie antagoniste, une à l'arrêt et une en mouvement, telles que les mobiles dans chaque zone ont les mêmes positions et que les mobiles dans la zone de conflit ont mêmes vecteurs-vitesse, l'interaction de la catégorie antagoniste en mouvement sera toujours plus sévère que l'interaction de la catégorie antagoniste à l'arrêt selon l'indicateur de proximité. Nous distinguons la catégorie antagoniste en mouvement pour ces raisons. Néanmoins, il n'est pas possible de comparer a priori les sévérités entre les interactions non-critiques de la catégorie antagoniste en mouvement et les interactions, toutes non-critiques, de la catégorie antagoniste à l'arrêt, en particulier selon l'indicateur de vitesse. Nous étudions globalement les interactions de la catégorie antagoniste, ainsi que séparément les interactions de la catégorie antagoniste en mouvement.

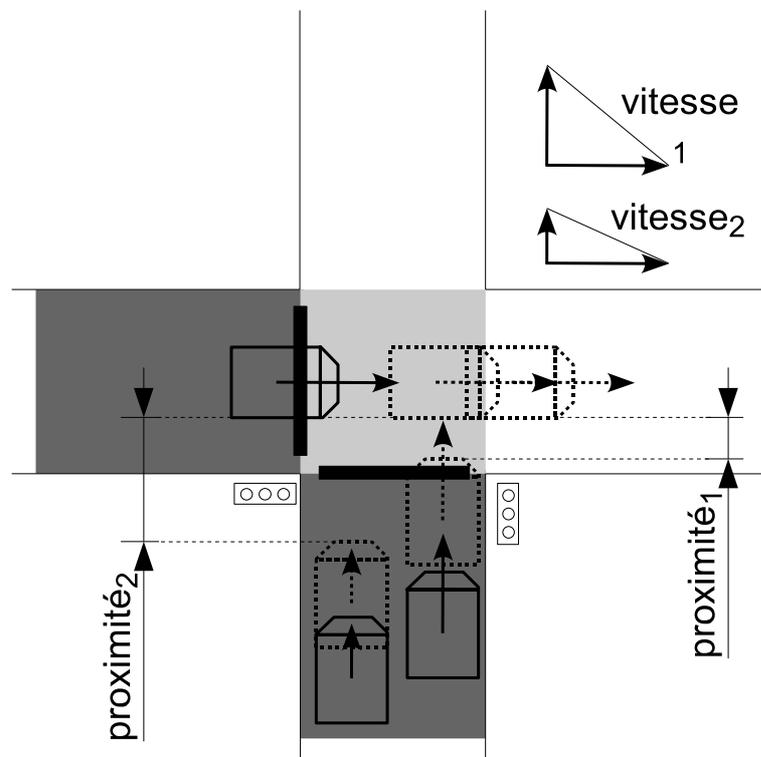


FIGURE 3.7 – Illustration de la qualification d'un instant selon les indicateurs de sévérité pour deux interactions de la catégorie antagoniste en mouvement. Les mobiles en pointillés indiquent leurs positions extrapolées lorsque les distances des mobiles en interaction sont minimales. Les indicateurs d'indice 1 sont les plus sévères.

Nous avons vu dans la partie précédente que nous détectons l'existence d'interactions par catégorie étudiée à chaque instant, et que nous ne sommes pas en mesure de distinguer les interactions d'une même catégorie, même entre groupes de mobiles. Pour qualifier la sévérité de cet ensemble d'interactions de même catégorie, nous estimons *la valeur la plus sévère de chaque indicateur* (cf figure 3.7). Cela nous permet en particulier de ne pas manquer les interactions les plus sévères dans nos catégories. Pour résumer, nous détectons à chaque instant l'existence d'interaction des catégories étudiées, et qualifions chaque instant selon les indicateurs de sévérité dans chaque catégorie.

3.3.3 Limites et discussion

Nous mettons l'accent sur les interactions entre mobiles appartenant à des courants différents pour comparer l'impact de stratégies de régulation sur le risque. L'impossibilité de détecter des interactions entre mobiles dans un même peloton ne nous prive pas d'interactions importantes pour notre travail.

La limite principale imposée par les données tient à la mise de côté des interactions entre mobiles en mouvement dans une même zone. Ce type d'interaction couvre tous les niveaux de sévérité, les démarrages et arrêts au sein d'un même peloton, à vitesses faibles et donc peu sévères, et les quasi-accidents, les interactions critiques les plus proches de l'accident, qui se poursuivent jusqu'à ce que les protagonistes soit très proches. Ces interactions sont incluses dans nos catégories et peuvent être marginalement détectées, mais ne peuvent pas être différenciées du reste des interactions nettement moins sévères.

La définition spatio-temporelle des données implique que nos indicateurs de sévérité ne peuvent prendre que quelques *valeurs discrètes*. La conjonction de sévérités très élevées pour ces deux indicateurs indique selon leur définition des interactions proches de l'accident. Cependant, nous ne pouvons pas détecter ces interactions les plus sévères, puisqu'elles se déroulent pour la plupart entre des protagonistes dans une même zone de conflit ou que la définition des données ne permet pas d'estimer cette sévérité élevée. Pour des raisons liées aussi à la définition spatio-temporelle des données, nous négligeons dans les estimations des indicateurs de sévérité des interactions de la catégorie antagoniste en mouvement la vitesse des mobiles dans la zone de stockage antagoniste. Les différences de sévérité entre les interactions des deux sous-catégories de la catégorie antagoniste, telles qu'exprimées par l'indicateur de proximité, n'apparaîtront donc pas dans nos études. Nous distinguons cependant les interactions de la catégorie antagoniste en mouvement puisqu'une partie de ces interactions est critique, à la différence des interactions de la catégorie antagoniste à l'arrêt.

Le choix des sévérités les plus élevées pour qualifier chaque instant d'interaction pose une limite inférieure aux valeurs de sévérités les plus faibles relevées. Cela donne une distribution des interactions selon leur sévérité différente de la "vraie" distribution qui seraient obtenue avec un système d'observation parfait. Nous ne comptons qu'une partie des interactions des sévérités plus faibles. Cela nous permet cependant de ne pas manquer les interactions les plus sévères dans nos catégories.

3.3.4 Objectifs du travail et interprétation des données

Le contexte d'une interaction

Pour le traitement postérieur des interactions étudiées, nous notons certaines caractéristiques, que nous appelons *contexte de l'interaction*. Nous effectuons les mêmes traitements sur les quatre intersections constituant le carrefour étudié. Nous relevons donc l'intersection sur laquelle une interaction a lieu, ceci pour deux raisons. Premièrement, nous voulons analyser les résultats selon l'intersection car les interactions qui s'y déroulent sont différentes. Deuxièmement, les données proviennent de huit capteurs vidéo différents, placés à des hauteurs et des angles différents, ce qui peut entraîner des distorsions spatiales différentes selon le capteur. Un pavé ne correspondra certainement pas à la même surface selon l'intersection. Les mesures estimées à partir de ces données ne sont donc pas comparables entre elles.

Nous ajoutons l'information sur l'*origine* du mobile qui vient d'entrer dans la zone de conflit, correspondant au mobile suivi pour la description des catégories d'interactions. Il s'agit de la zone d'origine du mobile entrant dans la zone de conflit en second pour la catégorie aval, et en premier pour la catégorie antagoniste. Cet attribut peut prendre deux valeurs, tronçon d'entrée (extérieur) ou zone de stockage interne (centre), qui sont pour chaque intersection les deux possibilités d'origine des mobiles qui y entrent. L'argument des mesures difficilement comparables liées aux pavés est encore valable. De plus, les distributions de vitesse sont très différentes selon que les mobiles viennent de l'extérieur du carrefour ou d'une autre zone de conflit et selon la zone de conflit. Par exemple, sur l'axe Paris-Banlieue, communiquant avec l'autoroute, dans les deux sens, les feux sont longtemps verts simultanément, et les vitesses peuvent être très élevées.

Nous notons enfin la *catégorie* de l'interaction détectée. Le contexte de l'interaction est ainsi constitué par le triplet lieu de l'interaction (zone de conflit), origine, et catégorie. Les indicateurs de sévérité des interactions seront mesurés avec des critères différents selon le contexte, et les échelles construites sont donc locales à chaque contexte.

Les entrées-sorties du système

Nous allons décrire dans les chapitres suivants une méthode de détection des catégories d'interactions décrites plus haut, et de qualification de leur sévérité selon les indicateurs proposés. Récapitulons les spécifications de ce système. Les entrées sont les suivantes,

- l'image du carrefour au niveau des pavés à un instant t , qui permet de reconstituer aussi l'image au niveau des zones,
- les états des feux du carrefour.

Les sorties sont les suivantes,

- l'existence d'interactions à l'instant t dans chaque contexte (*lieu, origine, catégorie*),
- l'estimation des indicateurs de sévérité, proximité et vitesse, dans chaque contexte (valeurs les plus sévères selon chaque indicateur).

Interprétation des résultats

Nous obtenons ainsi un ensemble d'instantanés d'interaction, qualifiés selon deux indicateurs de sévérité, proximité et vitesse, dans chaque contexte. Nous relevons les durées d'interaction dans un même nombre d'échantillons par stratégie, de caractéristiques aussi semblables que possible, en particulier pour les conditions de trafic (demandes de trafic globales et surtout sur les entrées correspondant au contexte des interactions).

Dans ce cadre, nous définissons l'*exposition* comme une durée d'interaction. Cette définition correspond aux définitions classiques d'un temps passé sur la route, et de certaines situations de trafic (Spence et Lassarre, 2003), les interactions en l'occurrence.

Nous comparons les expositions totales i.e. la durée d'interactions indépendamment de leurs niveaux de sévérité. Nous reprenons les deux courbes principales de (Svensson, 1998), représentant la *distribution des expositions* et des *pourcentages d'exposition* en fonction du niveau de sévérité, pour chaque contexte et indicateur de sévérité. La distribution des expositions indique pour l'utilisateur la vraisemblance d'être impliqué dans une intersection d'une certaine sévérité. Dans la distribution des pourcentages d'exposition, les expositions pour chaque niveau de sévérité sont divisées par l'exposition totale. Cette distribution permet de s'affranchir des différences de conditions des échantillons. Ces pourcentages représentent la probabilité de la sévérité de l'interaction, une fois que le mobile est impliqué dans une interaction. Nous utilisons aussi un test statistique qui détermine si les distributions sont égales.

Nous reprenons les conclusions de la partie 2.3.1 sur l'usage de l'"exposition". Puisque nous ne connaissons pas la relation entre les interactions que nous étudions et la demande de trafic, calculer des taux d'interaction donnerait des résultats sans signification. Nous préférons comme Å. Svensson comparer des échantillons de la base de données ayant des conditions de trafic semblables.

Une piste d'interprétation consiste à imaginer ce que pourrait être une stratégie de régulation conçue pour la sécurité. Selon notre approche et nos hypothèses, une telle stratégie éviterait de mettre en présence dans la zone de conflit des mobiles d'origines différentes. Pour cela, elle devrait éviter, lors du passage de mobiles dans la zone de conflit, la présence de mobiles dans la zone de stockage antagoniste, ou, s'il y a des mobiles dans la zone de stockage antagoniste, essayer de minimiser la sévérité de leurs interactions, telle qu'elle est mesurée par nos indicateurs. Nous pouvons analyser l'impact des stratégies étudiées à l'aune de ces stratégies imaginaires. A demande équivalente, sous quelle stratégie y'a-t-il le plus d'interactions de la catégorie antagoniste ? Sous quelle stratégie les passages de mobiles sont-ils les plus sévères, en exposition ou proportion de l'exposition totale ? Pour les raisons qui nous ont fait distinguer la catégorie antagoniste en mouvement, nous étudions la stratégie sous laquelle la proportion d'interactions de la catégorie antagoniste en mouvement parmi les interactions de la catégorie antagoniste est la plus importante ? De plus, une stratégie conçue pour la sécurité devrait s'assurer que la zone de conflit est vide avant de faire entrer de nouveaux mobiles. A demande équiv-

alente, sous quelle stratégie y'a-t-il le plus d'interactions de la catégorie aval à l'arrêt ? Sous quelle stratégie sont-elles les plus sévères ?

Nous ne savons pas quel est le lien exact des interactions relevées à l'accident, en particulier du fait de l'absence des interactions les plus sévères. Å. Svensson postule l'existence d'une frontière dans l'échelle de sévérité au-dessus de laquelle un fort taux d'interaction est un signe d'insécurité et en-dessous de laquelle c'est un signe de fonctionnement normale d'une intersection (Svensson, 1998). Nous ne savons pas où cette frontière se place selon les indicateurs de proximité que nous utilisons. L'absence des interactions les plus sévères se déroulant entre des interactions dans la même zone est un argument pour placer cette frontière au-dessus des interactions les plus sévères que nous détectons. Bien qu'une exposition suffisamment importante pour des interactions peu sévères peut être signe de sécurité, il n'est pas possible de tirer des conclusions sans connaître la totalité de la distribution des interactions, et en particulier les plus sévères.

Enfin, si le lien des éléments relevés au risque d'accident est difficile à établir, nous pouvons aussi voir ces résultats comme des informations détaillées sur le fonctionnement d'un carrefour.

3.4 Conclusion

Nous avons présenté une modélisation des interactions pour étudier l'impact des stratégies de régulation sur le risque des usagers, ainsi qu'une approche générique pour construire ces catégories, qui peut être appliquée à d'autres problèmes de sécurité. Après avoir décrit les données traitées, nous avons simplifié les objectifs de notre travail. Nous décrivons dans les chapitres suivants un système modulaire pour les atteindre. La tâche se divise logiquement en deux modules, traitant l'information séquentiellement,

1. la détection des interactions,
2. l'évaluation des indicateurs de sévérité, proximité et vitesse, des interactions détectées.

Ces deux modules nécessitent l'utilisation des données à leurs deux niveaux de description. Le premier module de détection peut se contenter d'utiliser des informations au niveau des zones, le second implique d'utiliser les données au niveau des pavés, car les informations de distance et de vitesse ne sont disponibles qu'à ce niveau. Les méthodes mises en œuvre sont aussi de natures différentes,

- système à base de règles explicites (chapitre 4),
- apprentissage artificiel¹⁰ à partir d'exemples étiquetés (chapitre 5).

Les données au niveau des zones sont suffisamment interprétables par un expert pour permettre l'explicitation de règles pour la détection des interactions. Pour autant, nous voulons développer une méthode générique pour construire des modules associant automatiquement un indicateur de sévérité à des interactions. Nous disposons en effet des

10. C'est la traduction de "machine learning" adoptée dans (Cornuéjols *et al.*, 2002).

enregistrements vidéo de l'expérience ayant fourni la base de données. Un expert peut observer ces enregistrements et étiqueter la sévérité des interactions détectées. Nous nous retrouvons dans le cas d'un problème d'apprentissage à partir d'exemples étiquetés. En ce qui concerne les deux indicateurs proposés, seul l'indicateur de vitesse nécessite un apprentissage par l'exemple, du fait de la dissémination et du bruitage des informations de vitesse dans les données. Par contre, l'indicateur de proximité peut être simplement calculé comme un nombre de pavés identifiés par le premier module de détection des interactions. Cette architecture modulaire a fait l'objet d'une présentation (Saunier *et al.*, 2004b). Les modules sont développés dans les chapitres suivants.

Résumé

- Nous avons proposé une modélisation des interactions en catégories basée sur les zones fonctionnelles d’une intersection, suivant le cheminement d’un mobile dans une intersection.
- Pour comparer l’impact de stratégies de régulation sur la sécurité, nous étudions des interactions entre des mobiles dont au moins un des mobiles protagonistes est situé dans la zone de conflit, avec un mobile dans la zone de conflit (catégorie aval) ou un mobile dans la zone de stockage antagoniste (catégorie antagoniste).
- Le site expérimental est complexe, constitué de quatre intersections de routes à sens unique. Nous avons enregistré toutes les données d’une expérience réelle sur ce carrefour, pendant laquelle la stratégie CRONOS développée au laboratoire Carrefour Intelligent de l’INRETS a été comparée à une stratégie de Référence de type micro-régulation. Les données surfaciques, générées toutes les secondes, contiennent des informations sur la présence et la dynamique des mobiles. Elles sont utilisées de façon brute ou agrégées au niveau des zones.
- Etant données les limites des données (les mobiles ne sont pas identifiés, ni individualisés), nous travaillons sur des groupes de mobile(s). Nous ne pouvons détecter des interactions au sein d’un même peloton de mobiles, ni dans une même zone, hormis si un protagoniste est à l’arrêt et l’autre en mouvement. Nous devons donc restreindre la catégorie aval aux interactions entre mobiles en mouvement et mobiles à l’arrêt. Nous écartons aussi le nombre d’interactions et le suivi des mobiles et des interactions entre les images. Nous analysons l’existence d’interactions par catégorie image par image.
- La composante gravité de l’accident potentiel n’est pas disponible dans les données. Nous évaluons la sévérité des interactions à l’aide de deux indicateurs, un indicateur de proximité, la proximité minimale extrapolée entre les protagonistes, et un indicateur de vitesse, le différentiel des vitesses des protagonistes. Ces indicateurs mesurent la distance spatio-temporelle entre les protagonistes. Nous qualifions chaque instant d’interaction par la valeur la plus sévère de chaque indicateur.
- Le contexte d’une interaction est le triplet constitué par son lieu, i.e. la zone de conflit du carrefour où se déroule l’interaction, l’origine du mobile dont l’entrée est détectée dans la zone de conflit et la catégorie de l’interaction.
- L’exposition est une durée d’interaction. Nous comparons les stratégies selon leur exposition totale et les distributions de l’exposition selon les indicateurs de sévérité.
- Nous proposons une architecture modulaire de traitement de l’information. A chaque seconde, le premier module détecte l’existence d’interactions dans chaque contexte en traitant une image au niveau des zones, puis un second module évalue la sévérité des interactions détectées en traitant les images au niveau le plus fin.

Le second [point], de diviser chacune des difficultés que j'examinerais en autant de parcelles qu'il se pourrait et qu'il serait requis pour les mieux résoudre.

Le troisième [point], de conduire par ordre mes pensées, en commençant par les objets les plus simples et les plus aisés à connaître, pour monter peu à peu, comme par degrés, jusques à la connaissance des plus composés; et supposant même de l'ordre entre ceux qui ne se précèdent point naturellement les uns les autres.

Discours de la méthode,
René Descartes

4

Des règles pour la détection des interactions et l'estimation de l'indicateur de proximité

Sommaire du chapitre

4.1	Introduction	57
4.1.1	Le contexte	57
4.1.2	Intelligence artificielle et systèmes experts	58
4.2	La détection des interactions	58
4.2.1	Les formes	59
4.2.2	Le franchissement de la ligne de feu	61
4.2.3	Les interactions	62
4.3	L'indicateur de proximité	65
4.3.1	Extrapolation des trajectoires	65
4.3.2	Calcul de l'indicateur de proximité	66
4.4	Validation	68
4.4.1	Introduction	68
4.4.2	La détection des interactions	69
4.4.3	L'indicateur de proximité	71
4.4.4	Remarques	72
4.5	Conclusion	73

4.1 Introduction

4.1.1 Le contexte

Nous présentons dans ce chapitre un système à base de règles pour traiter les données, détecter automatiquement les interactions des catégories décrites dans le chapitre précédent¹ et estimer un indicateur de sévérité, l'indicateur de proximité. Le choix d'un

1. Nous détectons à proprement parler des instants d'interaction, mais nous faisons l'abus de langage dans la suite.

système à base de règles s'appuie sur notre capacité à interpréter les données au niveau de description des zones dans ce but.

Nous avons déjà vu que des systèmes permettant la détection automatique des interactions critiques n'existent pas. Leur arrivée et leurs intérêts supposés sont cependant anticipés depuis longtemps (Kulmala, 1995), avec les promesses et réussites des Technologies de l'Information et de la Communication (TIC). Les systèmes limités existant se basent en général sur des capteurs vidéo et se concentrent sur le développement de systèmes de traitement d'image.

4.1.2 Intelligence artificielle et systèmes experts

Nous montrons dans ce chapitre comment nous avons transféré la connaissance experte des interactions et des données dans notre système automatique. Les *systèmes à base de règles* font partie des *systèmes experts* qui sont parmi les plus connues et les plus anciennes réussites de l'*Intelligence Artificielle* (IA). L'IA est définie par l'Association Américaine pour l'IA² comme "la compréhension scientifique des mécanismes sous-jacents de la pensée et du comportement intelligent, et leur mise en œuvre dans des machines"³.

Le but originel de l'IA est ainsi double : d'une part, construire des systèmes dont le comportement peut être qualifié d'intelligent, comme ceux des êtres vivants, mais pas exclusivement; d'autre part comprendre les comportements et le fonctionnement des êtres vivants en le modélisant et le testant dans des systèmes artificiels. Il faudrait alors définir le terme intelligence. Il couvre un grand nombre de compétences cognitives observables chez des êtres vivants comme la résolution de problèmes, l'apprentissage ou la compréhension du langage. L'IA, née après la seconde guerre mondiale, est une discipline jeune, mais à l'histoire déjà mouvementée, et émaillée de controverses. Les systèmes experts sont apparus dans les années 1970, dans le courant mettant l'accent sur les connaissances, leur représentation et l'utilisation de règles d'inférence, avec par exemple les projets DENDRAL et MYCIN. L'usage de systèmes experts s'est ensuite répandu à partir des années 1980 dans l'industrie. Un exemple dans le domaine du transport et développé à l'INRETS est CLAIRE, un système indépendant de supervision de la congestion du trafic routier présenté dans la partie 2.1.3. Le domaine des systèmes experts est un des domaines de l'IA les plus matures par le nombre de ses utilisations pratiques.

4.2 La détection des interactions

Les données sont interprétables au niveau des zones pour permettre de reconstituer des mouvements de mobiles entre zones. Les catégories des interactions présentées au chapitre précédent peuvent se décrire en configurations simples de ces mouvements. Interpréter les données au niveau des zones signifie que nous ne cherchons pas à recon-

2. American Association for Artificial Intelligence, cf <http://www.aaai.org>.

3. "The scientific understanding of the mechanisms underlying thought and intelligent behavior and their embodiment in machines."

naître des configurations précises de pavés, qu'il est suffisant par exemple d'utiliser des taux par zone de pavés dans les différents états. Nous allons préciser ce point dans cette partie. Tous les choix présentés ici sont évalués et discutés à la fin du chapitre.

4.2.1 Les formes

Nous avons introduit les données dans le chapitre précédent, et décrit les contraintes découlant de leurs caractéristiques, en particulier la non-individualisation des mobiles. Nous disposons cependant d'information de présence, qui peuvent être interprétées de la façon suivante.

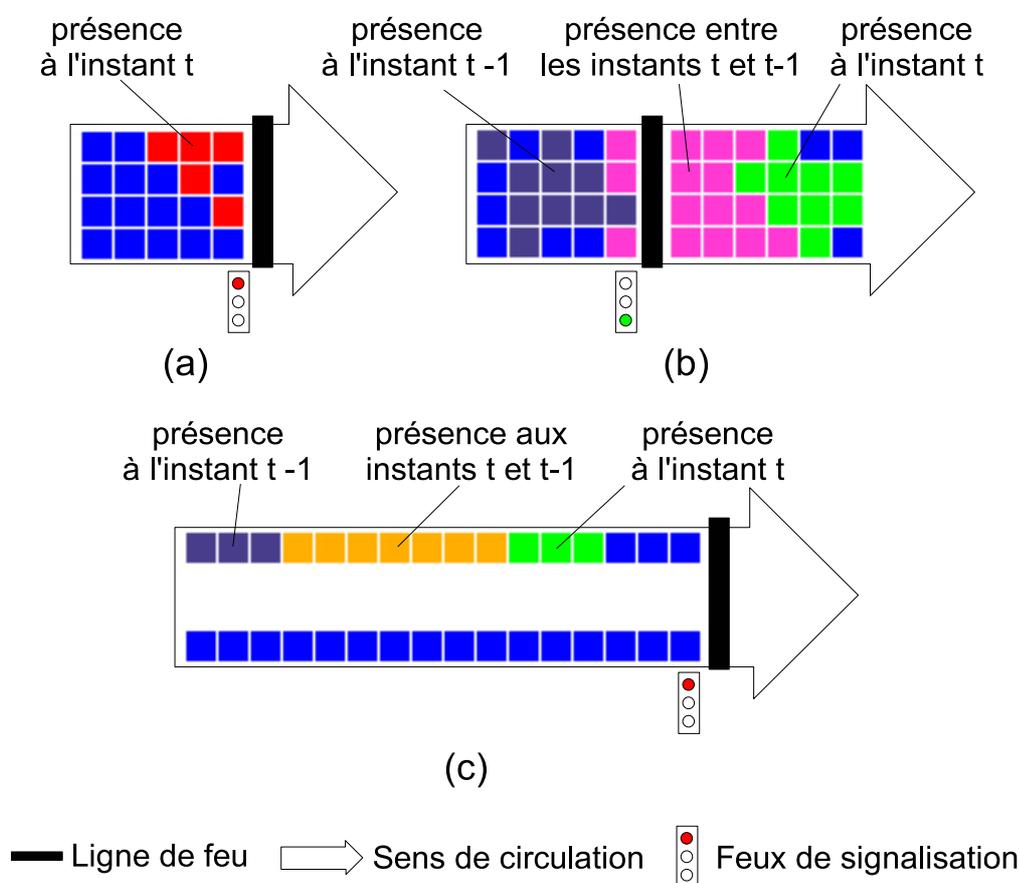


FIGURE 4.1 – Présentation de zones interprétables. Un mobile ou un groupe de mobiles (a) est à l'arrêt derrière une ligne de feu, (b) est entré dans la zone de conflit après franchissement de la ligne de feu, (c) se déplace plus lentement vers la ligne de feu (l'information est linéaire sur les entrées du carrefour, cf partie 3.2.3). La légende complète des informations d'occupation se trouve sur la figure 3.3.

Nous avons dans les premiers temps de notre recherche tenté d'interpréter les données au niveau des pavés. Un expert peut s'habituer et percevoir le mouvement global des mobiles dans les pavés. La figure 4.1 donne quelques exemples d'images interprétables. Nous partons de l'hypothèse que l'information seule d'un pavé isolé peut être du bruit, mais que c'est beaucoup moins probable lorsque plusieurs pavés voisins indiquent

une information cohérente, comme de la présence. Nous avons donc étudié des ensembles spatialement connexes de pavés dans le même état de présence que nous appelons *formes*. Nous relevons les formes de présence en mouvement, correspondant aux états des pavés début, trace, fin de présence et présence en mouvement, ainsi que les formes de présence à l'arrêt. Malheureusement, ces formes ne sont pas complètement corrélées avec des pelotons de mobiles. Deux formes peuvent être nettement séparées spatialement par du vide sans qu'il y ait deux groupes distincts de mobiles dans le trafic. Le nombre de formes indépendantes détectées ne correspond pas au nombre de groupes de mobiles dans la réalité. Cependant, la détection d'au moins une forme indique de façon robuste la présence d'au moins un groupe de mobiles, en mouvement ou à l'arrêt selon la forme. Nous avons alors abandonné l'étude des formes détectées pour nous limiter à la présence ou l'absence de forme dans une zone. De ce point de vue, nous étudions les données au niveau de la zone, sans chercher à interpréter précisément les pavés. Ce choix rejoint celui de ne pas étudier les interactions entre mobiles situés dans une même zone.

Cette restriction sur la détection des interactions dans chaque contexte a des conséquences sur les indicateurs de sévérité. S'il est détecté au moins une interaction dans un contexte donné, un indicateur de sévérité qualifie alors globalement la ou les interactions détectées dans ce contexte. Nous avons choisi la valeur la plus sévère de chaque indicateur afin de ne pas manquer les interactions les plus sévères dans nos catégories. Nous parlons d'indicateurs de sévérité par contexte.

Il y a différentes façons de faire cette détection. Il faut préciser que nous considérons les zones indépendamment, et donc les formes sont des sous-ensembles de pavés d'une seule zone. Notre modélisation est en effet basée sur les zones fonctionnelles d'une intersection. Les pavés sont regroupés par zone dans les données.

Un paramètre important est le voisinage choisi pour constituer les formes (cf tableaux 4.1 pour deux exemples de voisinages). Nous avons choisi le voisinage le plus réduit, suffisant pour notre travail. Le second paramètre important est la taille minimale des formes considérées. A partir de combien de pavés une forme est-elle considérée comme indiquant la présence d'au moins un mobile? Nous constatons empiriquement que les résultats sont robustes à partir de deux pavés pour les formes de présence en mouvement. Pour les formes de présence à l'arrêt, le seuil est relevé à trois pavés. Les détails d'implémentation concernant la constitution des formes sont détaillés dans l'annexe A.3.

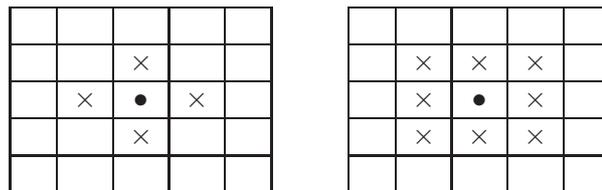


TABLE 4.1 – Différents types de voisinages. Les cases marquées d'une croix sont voisines de la case centrale marquée d'un rond noir. Le voisinage défini dans le tableau de gauche est le plus réduit possible. Celui du tableau de droite élargit le premier aux cases diagonales les plus proches.

Aux règles de constitution des formes, nous avons ajouté quelques règles pour remédier aux plus importants problèmes de masquage. Le masquage trompe le traitement d'image qui détecte de la présence supplémentaire. Nous avons traité deux cas pour lesquels nous pouvions remédier partiellement au problème causé par le passage de mobiles dans la zone de conflit, induisant la fausse détection de mouvement dans la zone de stockage antagoniste. Les deux cas correspondent au fait que la zone de stockage antagoniste est une entrée du carrefour ou située dans le centre du carrefour. Les problèmes sont différents. Dans le cas du centre du carrefour, nous voulons limiter la détection de formes en mouvement dues à ce phénomène, et pour cela ignorons les formes dont les pavés se situent dans la première ligne de pavés plus proche de la ligne de feu. Dans le cas des entrées du carrefour, ces formes en première ligne de la zone de stockage n'existent pas puisque chaque voie est représentée par une ligne de pavés. Des formes de présence en mouvement apparaissent cependant sur chaque voie, masquant en particulier des formes de présence à l'arrêt généralement fiables. Pour remédier à cela, nous avons rendu les formes de présence en arrêt persistantes tant que le feu contrôlant l'accès à la zone de conflit aval est rouge (les changements d'état des pavés constituant ces formes sont ignorés). Nous n'avons pas noté d'inconvénient majeur lié à cette règle, en particulier quant à des mobiles qui démarreraient alors que le feu est encore rouge. Pour les zones de stockage du centre du carrefour, cette règle crée trop de nouveaux problèmes : alors qu'il y a encore des mobiles en mouvement dans la zone, les formes de présence en mouvement sont souvent cachées par les formes persistantes de présence à l'arrêt. De plus, les formes de présence à l'arrêt sont rarement complètement masquées. Cette règle n'est pas utilisée dans les zones de stockage du centre du carrefour.

4.2.2 Le franchissement de la ligne de feu

Pour pouvoir détecter les interactions de la catégorie antagoniste, il est nécessaire de connaître l'origine des mobiles détectés dans la zone de conflit pour déterminer la zone de stockage antagoniste. Pour toutes les catégories que nous étudions, il s'agit de l'élément origine du contexte d'une interaction.

Nous avons écarté les interactions entre mobiles présents dans une même zone (hormis s'il y a de la présence en mouvement et à l'arrêt), et nous jugeons la présence de mobiles au niveau de la zone. Pour des raisons similaires, nous faisons l'hypothèse simplificatrice que les mobiles entrés dans la zone de conflit entre deux images successives proviennent de la même zone de stockage.

Pour déterminer l'origine de mobiles en mouvement détectés dans la zone de conflit dans une image à l'instant t , nous estimons s'il y a eu un franchissement des lignes de feu menant à la zone de conflit sur la dernière seconde, entre $t - 1$ et t . Nous avons repris pour cela une méthode de détection des franchissements de la ligne de feu, développée par S. Midenet dans le cadre de ses travaux sur le franchissement au rouge et la commande de feux temps réel (Midenet, 1998). Des méthodes plus performantes mais aussi

plus complexes sont en développement, mêlant aux règles des techniques d'apprentissage basées sur des cartes auto-organisatrices de Kohonen.

Les règles précises sont décrites en annexe A.4. Un point important tient au fait de départager les ambiguïtés des règles en se fiant à la couleur des feux. En général, le franchissement aura effectivement lieu sur la ligne dont le feu n'est pas rouge. Il n'est pas possible de faire confiance aux règles lorsqu'elles indiquent un passage sur les deux lignes de feu amont, en particulier à cause des masquages sur la zone de stockage antagoniste. Lorsqu'il y aura réellement passage sur les deux lignes de feu amont, l'interaction qui en résultera impliquera des mobiles en mouvement dans la zone de conflit, et fait donc partie des catégories que nous n'étudions pas.

4.2.3 Les interactions

Nous sommes maintenant en mesure de détecter la présence de mobiles par zone, et d'attribuer une origine aux groupes de mobiles en mouvement dans une zone de conflit. Ceci permet d'instancier des *primitives* décrivant ces états. Nous utilisons deux primitives, *mouvement* et *arrêt*. Elles prennent toutes les deux en paramètre une zone du carrefour, signifiant qu'il y a au moins un mobile dans la zone respectivement en mouvement ou en arrêt. La primitive *mouvement* peut prendre un second argument indiquant l'origine du ou des mobiles en mouvement dans la zone ($A \rightarrow B$ indique un mouvement de la zone A vers la zone B). Les zones sont référencées sur la figure 4.2.

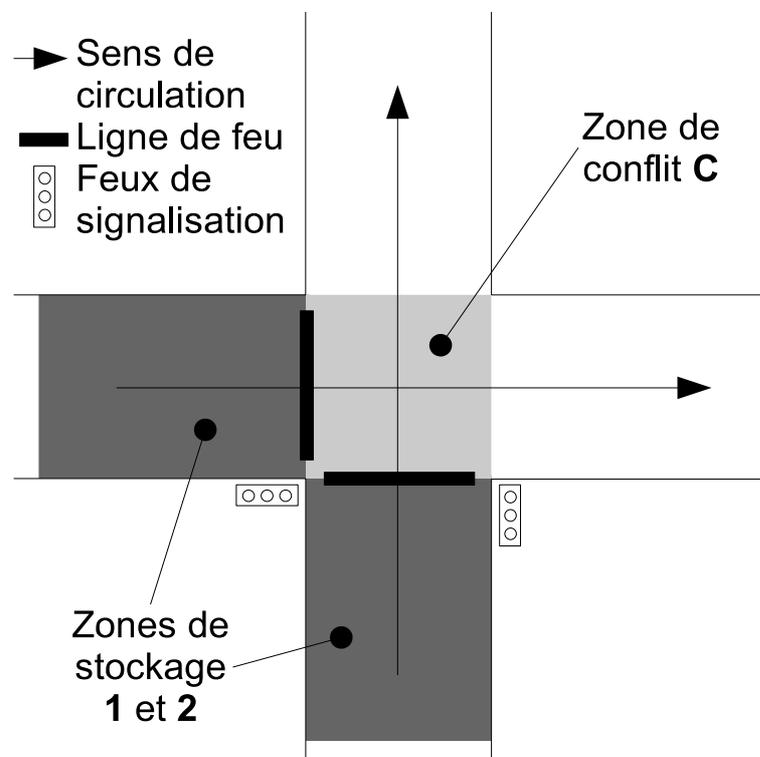


FIGURE 4.2 – Plan d'une intersection simple de notre carrefour, avec la zone de conflit notée C, et les deux zones de stockage amont notées 1 et 2.

Nous pouvons ensuite décrire les catégories d'interaction définies dans le chapitre précédent à l'aide de règles utilisant ces primitives. La détection des interactions se fait par instanciation directe des différentes catégories. Le tableau 4.2 décrit les règles de détection de toutes les catégories d'interaction de notre modèle, même si nous travaillons précisément sur les catégories aval à l'arrêt et antagoniste. Les figures 4.3, 4.4 et 4.5 montrent des exemples d'images menant à la détection d'interactions de ces catégories (l'état d'un pavé d'une zone aval de la zone de conflit n'est pas disponible). La connaissance de l'origine des mobiles en mouvement dans la zone de conflit est indispensable pour déterminer l'origine du contexte de l'interaction, la zone de stockage antagoniste pour les interactions de la catégorie antagoniste, et pour une meilleure détection des interactions de la catégorie aval à l'arrêt. Ceci permet d'éliminer une partie des fausses détections dues à l'apparition erronée de mouvement dans la zone de conflit, mais sans aucune entrée dans la zone.

Catégorie d'interaction	Règle
Amont seul	$mouvement(1)$
Amont	$mouvement_1(1) \cap mouvement_2(1)$
Aval en mouvement	$mouvement_1(C, 1 \rightarrow C) \cap mouvement_2(C, 1 \rightarrow C)$ $mouvement(C, 1 \rightarrow C) \cap mouvement(C, 2 \rightarrow C)$
Aval à l'arrêt	$mouvement(C, 1 \rightarrow C) \cap arrêt(C)$
Antagoniste à l'arrêt	$mouvement(C, 1 \rightarrow C) \cap arrêt(2)$
Antagoniste en mouvement	$mouvement(C, 1 \rightarrow C) \cap mouvement(2)$

TABLE 4.2 – Règles de description des interactions à partir des primitives *mouvement* et *arrêt*. $mouvement_1$ et $mouvement_2$ désignent des groupes de mobiles différents en mouvement. C désigne la zone de conflit, 1 et 2 les deux zones de stockage, dont le rôle est symétrique (cf figure 4.2). $A \rightarrow B$ indique un mouvement de la zone A vers la zone B . Nous étudions les 3 dernières catégories du tableau

Des paramètres doivent être réglés dans cette détection. Le plus important est la distance des mobiles à la ligne de feu à partir de laquelle sont relevées les interactions avec des mobiles en mouvement dans la zone de conflit. La valeur choisie est faible, pour limiter le nombre d'interactions relevées. Cependant, si le nombre d'interactions relevées pour une période donnée change en fonction de ce paramètre, il est raisonnable de supposer que les comparaisons entre les stratégies n'y sont pas sensibles.

A chaque instant t , le module de détection des interactions indique pour chaque zone de conflit, s'il existe au moins une interaction d'une des catégories étudiées, et identifie l'origine du mobile entré dans la zone de conflit. Un aspect très important du système développé est la simplicité et la compréhensibilité des règles de détection mises en œuvre. Cet aspect justifie le choix d'un système à base de règles pour cette tâche, étant donnée la connaissance experte disponible.

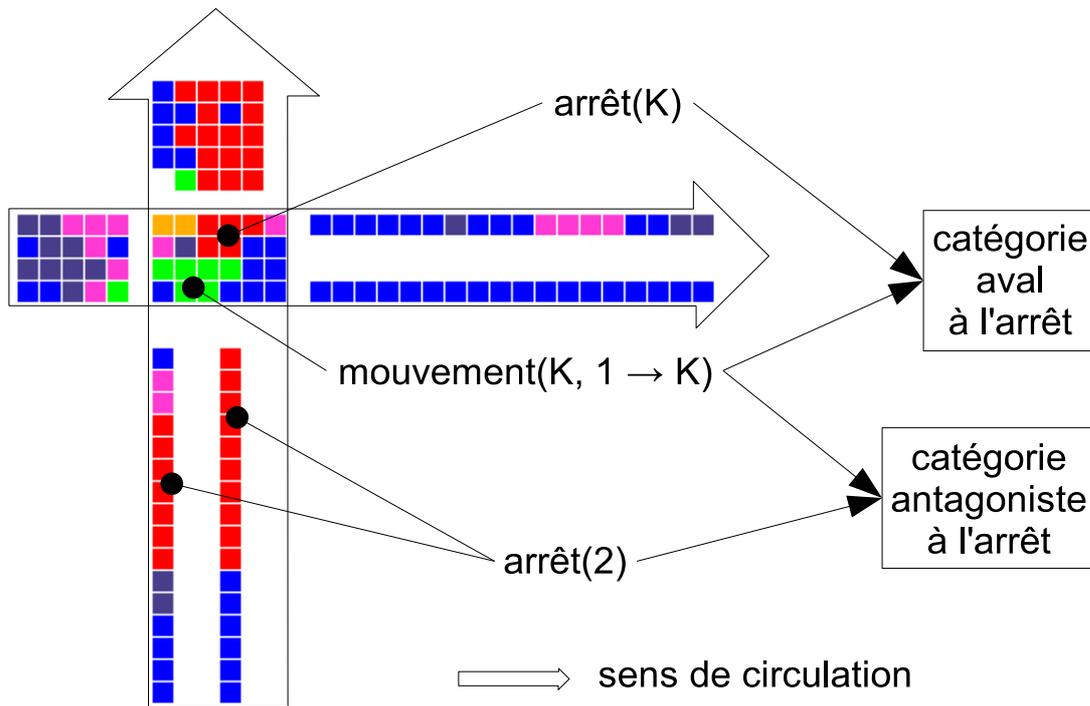


FIGURE 4.3 – Un exemple d'image conduisant à la détection d'interactions des catégories aval à l'arrêt et antagoniste à l'arrêt dans la zone de conflit K, d'origine le centre du carrefour.

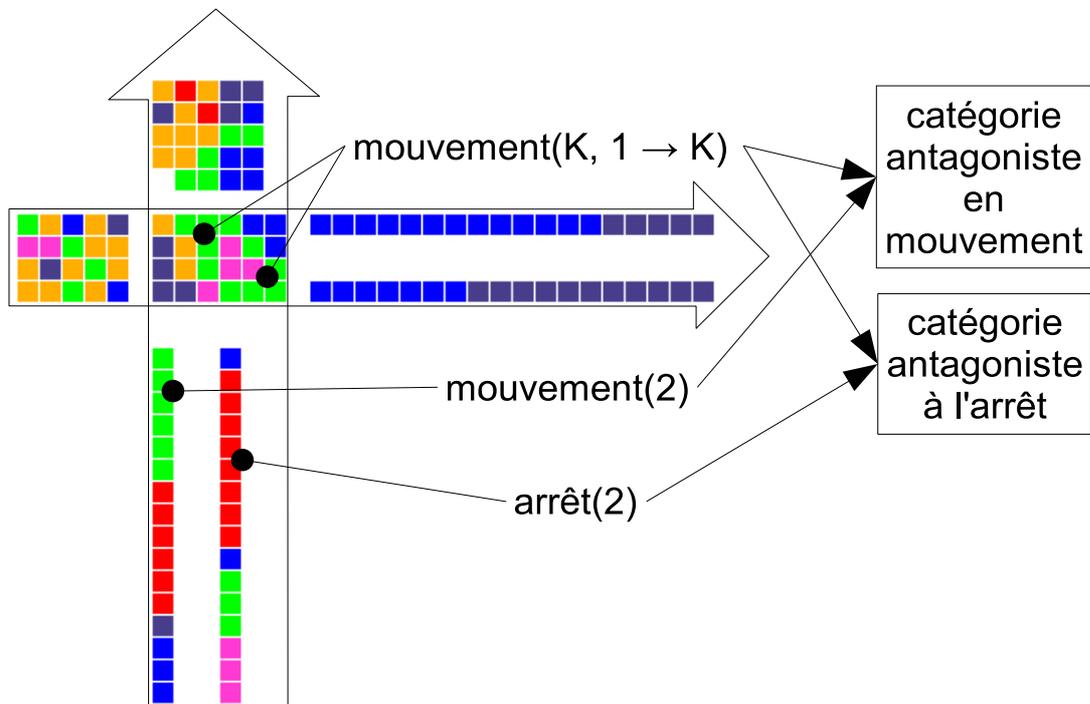


FIGURE 4.4 – Un exemple d'image conduisant à la détection d'interactions des catégories antagoniste à l'arrêt et en mouvement dans la zone de conflit K, d'origine le centre du carrefour.

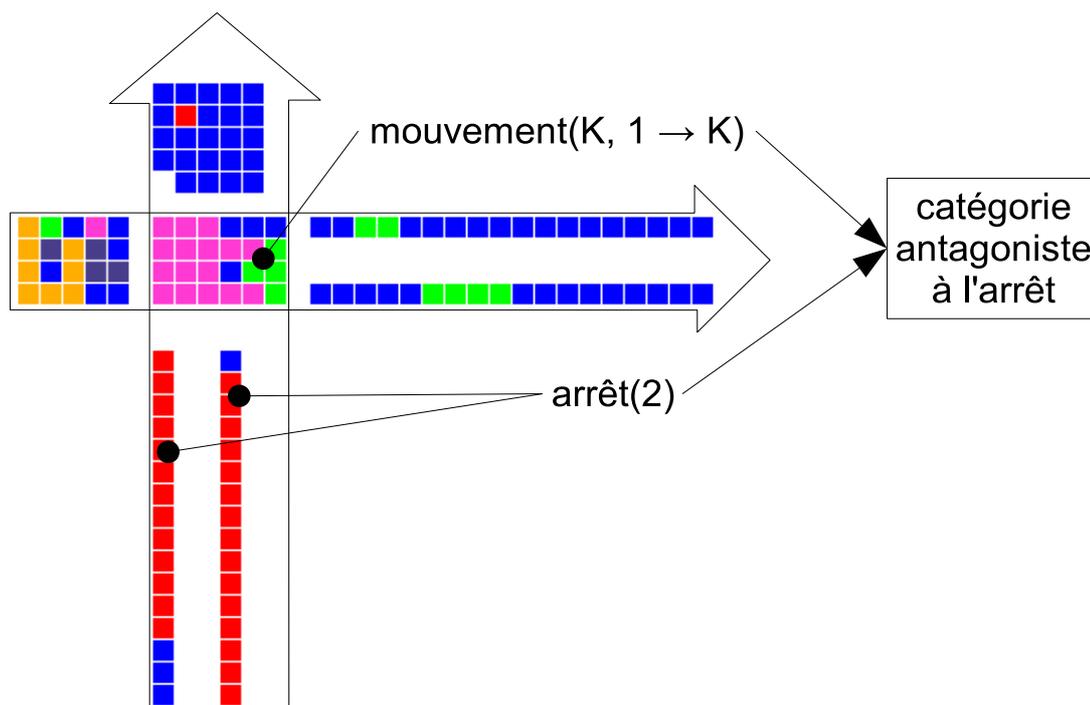


FIGURE 4.5 – Un exemple d’image conduisant à la détection d’interactions de la catégorie antagoniste à l’arrêt dans la zone de conflit K , d’origine le centre du carrefour.

4.3 L’indicateur de proximité

4.3.1 Extrapolation des trajectoires

Dans le chapitre précédent, l’indicateur de proximité des interactions est défini comme la distance minimale extrapolée à partir de l’instant de détection entre les deux mobiles protagonistes. Nous extrapolons les trajectoires des mobiles à vitesse et direction constantes.

Soit t l’instant de l’image dans laquelle une interaction est détectée. Soit t_{dmin} l’instant auquel la distance entre les positions extrapolées des protagonistes est minimale. Pour la plupart des vitesses des mobiles dans la zone de conflit, la durée $t_{dmin} - t$ est faible. Dans le cas de la catégorie aval ou antagoniste à l’arrêt, un des deux protagonistes est à l’arrêt à t , et selon nos hypothèses d’extrapolation, il ne va pas bouger entre t et t_{dmin} . Pour la catégorie antagoniste en mouvement, le mobile entrant dans la zone de conflit ne viole généralement pas le feu rouge, donc le mobile dans la zone de stockage doit s’arrêter à son feu rouge. Nous en déduisons que dans ce cas la vitesse du mobile dans la zone de stockage antagoniste est faible. Il est impossible de mesurer finement des vitesses faibles à partir des données. Puisque cette vitesse et $t_{dmin} - t$ sont faibles, et qu’il est impossible de mesurer cette vitesse, nous négligeons le déplacement du mobile en mouvement dans la zone de stockage antagoniste entre t et t_{dmin} .

Nous avons simplifié nos hypothèses et l’extrapolation de trajectoires ne concerne donc que le mobile entrant dans la zone de conflit pour toutes les interactions. Nous sup-

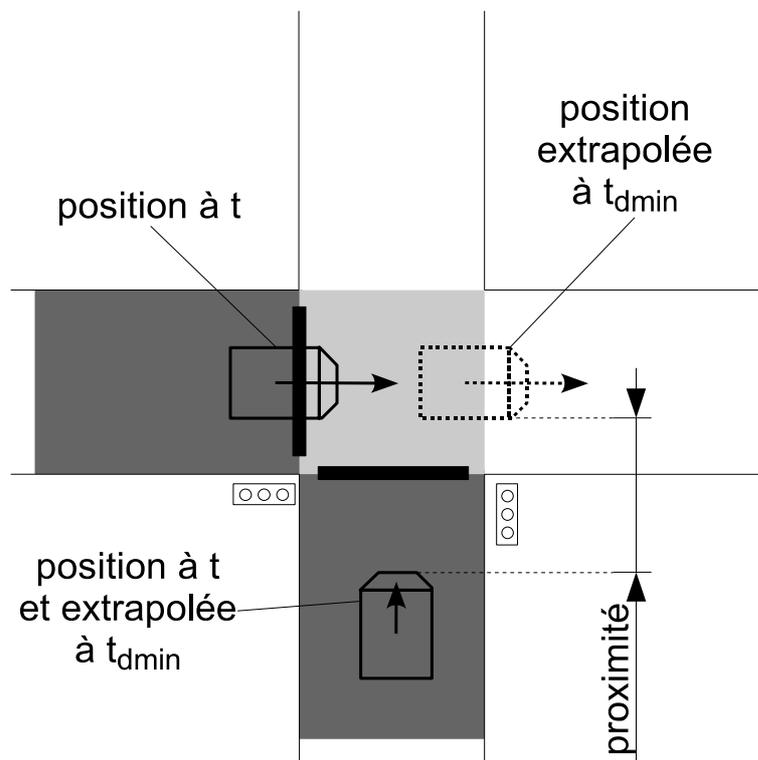


FIGURE 4.6 – Illustration de l’indicateur de proximité pour une interaction de la catégorie antagoniste en mouvement et des hypothèses simplifiées d’extrapolation des trajectoires.

posons qu’il traverse la zone de conflit tout droit sans faire d’écart latéral. L’indicateur de proximité des interactions détectées se ramène donc à la distance latérale, i.e. dans la direction normale à la direction du mobile, à un instant donné entre les deux protagonistes (cf figure 4.6).

Nous avons simplifié l’indicateur de proximité pour les interactions de la catégorie antagoniste en mouvement. Les interactions de la catégorie antagoniste en mouvement sont plus sévères selon l’indicateur de proximité que les interactions de la catégorie antagoniste à l’arrêt correspondantes, mais notre raisonnement précédent nous indique que cette différence n’est pas mesurable dans notre cas.

4.3.2 Calcul de l’indicateur de proximité

Dans une image, les informations de distance en terme de pavés sont directement accessibles. Nous pouvons donc directement calculer la distance latérale entre les formes relevées pour la détection des interactions. Pour chaque contexte (lieu, origine, catégorie), le premier module indique s’il y a au moins une interaction ou pas. L’indicateur de proximité dans un contexte donné est l’indicateur de proximité de l’interaction la plus sévère dans ce contexte, i.e. la distance minimale extrapolée entre couples de mobiles protagonistes la plus faible. Il se calcule comme la distance latérale la plus faible entre les formes ayant conduit à la détection de l’existence d’interactions (cf figure 4.7).

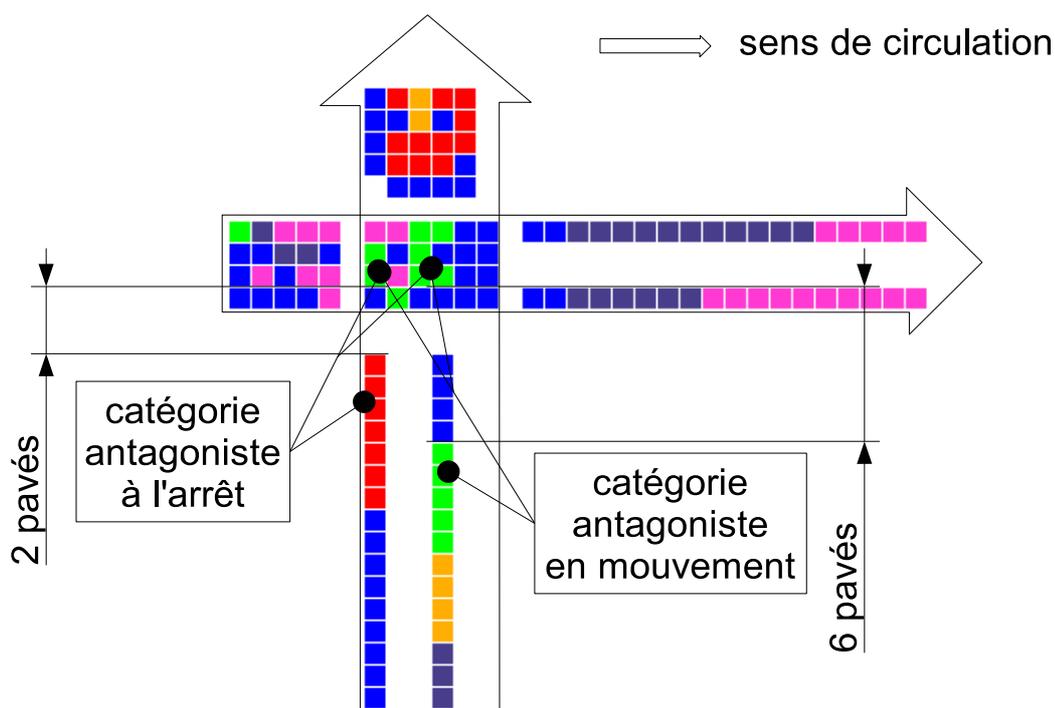


FIGURE 4.7 – Un exemple de calcul de l'indicateur de proximité pour deux interactions des catégories antagonistes à l'arrêt et en mouvement dans la zone de conflit K, d'origine le centre du carrefour. La valeur la plus sévère de l'indicateurs de proximité pour les interactions de la catégorie antagoniste est 1. Le pavé dans l'état "début de présence" (vert) situé dans la zone de conflit, le plus proche de la ligne de feu, sans voisin dans le même état, n'est pas pris en compte puisqu'il ne fait pas partie d'une forme.

Pour des raisons de simplicité lors des calculs de distance, la valeur la plus faible est la plus sévère. La valeur minimale peut être nulle pour les interactions de la catégorie aval à l'arrêt, lorsque le mobile en mouvement entrerait en collision s'il se déplaçait en ligne droite. Pour les interactions de la catégorie antagoniste, la valeur minimale est un pavé, lorsque les formes sont les plus proches possibles de la ligne de feu. Cela marque le fait que les mobiles ne sont pas dans la même zone. La valeur maximale dépend de la distance à la zone de feu prise en compte pour la détection des interactions. Pour donner un ordre de grandeur, elle est de huit avec la valeur retenue pour nos études.

Il peut sembler étonnant de se fier aux formes de pavés pour cette tâche. Si leur nombre n'est pas fiable par rapport aux groupes de mobiles sur le carrefour, nous validons l'utilisation des distances entre ces formes dans la partie suivante. D'autre part, nos hypothèses d'extrapolation permettant de négliger le déplacement du mobile dans la zone de stockage antagoniste peuvent être violées. Si son déplacement est rapide, le mobile entrera certainement dans la zone de conflit ce qui pourra donner lieu à des interactions détectables dans un autre contexte, i.e. d'une catégorie et d'une origine différentes. Si le mobile en mouvement dans la zone de conflit se déplace lentement, $t_{dmin} - t$ peut devenir significatif, et l'indicateur de proximité être un peu sur-estimé.

4.4 Validation

4.4.1 Introduction

Nous présentons dans cette partie des résultats de validation de la méthode proposée pour la détection des interactions et l'estimation de l'indicateur de proximité. Nous voulons évaluer si les instants d'interaction sont bien détectés, et s'il y a des différences de performances de notre système automatique selon le contexte, i.e. l'intersection, l'origine du protagoniste traversant la zone de conflit et la catégorie d'interaction. Nous voulons aussi évaluer si la mesure simple de la distance transversale entre protagonistes est justifiée. Pour cela, nous avons comparé les sorties du système automatique à la réalité telle qu'un expert la perçoit dans les enregistrements vidéo.

Quelques remarques préliminaires. Nous avons choisi de travailler sur deux intersections, les premières rencontrées par les mobiles provenant de Paris et du Kremlin-Bicêtre (notées P et K sur la figure 3.2). Valider sur deux intersections est un bon compromis entre le temps nécessaire à une telle validation et la volonté de comparer le comportement du système sur différentes intersections. C'est aussi cohérent avec les modèles construits pour l'évaluation de l'indicateur de vitesse dans deux contextes correspondant à ces intersections. Nous validons ainsi la moitié des contextes du carrefour.

Nous avons utilisé une séquence d'environ 10 minutes de trafic du 2 novembre 1998, à partir de 8h20, intervalle de temps appartenant à un échantillon de trafic de pointe, sous la stratégie de Référence. Ces dix premières minutes ne permettent pas d'obtenir des effectifs suffisants dans tous les contextes envisagés. Seule la catégorie antagoniste peut être validée sur dix minutes. Les autres catégories, rares, nécessitent un temps supplémentaire de validation. Nous détectons l'existence d'interactions par contexte à chaque seconde. Du fait de décalages possibles entre les données et l'enregistrement vidéo observé par l'expert, nous faisons correspondre les résultats du système automatique et de l'expert au mieux à la seconde près.

Il ne faut pas oublier notre objectif, qui est de comparer l'impact de stratégies sur le risque des usagers. Nous devons pour cela nous assurer que les performances des modules validés ne dépendent pas de la stratégie. Les mesures de validation détaillées dans la suite ne doivent pas être sensiblement différentes entre les stratégies. Pour cela, nous utilisons des séquences comparables de données obtenues sous chaque stratégie. La seconde séquence, sous la stratégie CRONOS, provient du 12 janvier 1999.

La détection des interactions à chaque instant dans le carrefour et l'évaluation de l'indicateur de proximité peuvent se voir comme un problème de classification. Nous devons introduire au préalable quelques mesures de la performance de notre système automatique, que nous aborderons plus longuement dans le chapitre suivant sur l'apprentissage artificiel.

Nous calculons plusieurs mesures à partir de la *matrice de confusion*, qui contient à la position (i, j) le nombre d'objets de la classe c_i catégorisés par le système dans la classe

Correct \ Prédit	Classe 1	Classe 2
Classe 1	Vrais positifs (A)	Faux négatifs (B)
Classe 2	Faux positifs (C)	Vrais négatifs (D)

TABLE 4.3 – Matrice de confusion dans le cas binaire. Les éléments de chaque case ont un nom particulier dans le cas d'une classe particulière à détecter, dite "positive" (ici 1) contre une classe "négative" (ici 2).

c_j , noté $M_{i,j}$ (le tableau 4.3 présente une matrice de confusion dans le cas binaire). La mesure la plus utilisée est le couple *rappel/précision* pour chaque classe.

$$\text{Rappel} : R_1 = \frac{A}{A+B}, R_2 = \frac{D}{C+D}$$

$$\text{Précision} : P_1 = \frac{A}{A+C}, P_2 = \frac{D}{B+D}$$

Lorsque le problème est multi-classe, la formule des mesures de rappel/précision se généralise de la façon suivante pour une classe c (soient N_C le nombre de classes, R_c et P_c respectivement le rappel et la précision pour la classe c),

$$R_c = \frac{M_{c,c}}{\sum_{1 \leq j \leq N_C} M_{c,j}}$$

$$P_c = \frac{M_{c,c}}{\sum_{1 \leq i \leq N_C} M_{i,c}}$$

Considérées pour plusieurs classes simultanément, les mesures de rappel/précision sont liées. Si la précision pour une classe diminue, le rappel d'une autre diminue aussi. Pour avoir une image globale des performances, le taux d'erreur, ou son complémentaire, le taux de bonne classification sont utilisés :

$$\text{Taux de Bonne Classification} : t = \frac{A+D}{A+B+C+D}$$

Dans le cas général,

$$\text{Taux de Bonne Classification} : t = \frac{\sum_{1 \leq i \leq N_C} M_{i,i}}{\sum_{1 \leq i \leq N_C, 1 \leq j \leq N_C} M_{i,j}}$$

4.4.2 La détection des interactions

La détection d'une interaction peut se voir pour chaque contexte (lieu, origine) comme un problème de classification de chaque instant dans une classe, qui peut être une des catégories d'interactions ou l'absence d'interaction. Cela permet de mettre en lumière les erreurs de catégorie en détection. Nous avons cependant constaté très peu d'erreurs de ce type et nous préférons donc voir le problème pour chaque catégorie comme un problème de classification binaire de chaque catégorie (classe "positive") contre le reste à chaque instant.

Nous présentons les résultats pour les échantillons de trafic sous les deux stratégies. Nous présentons les résultats par catégorie, à commencer par la catégorie antagoniste, sur dix minutes à partir de 8h20 en condition de trafic de pointe (cf tableau 4.4). Les résultats sont satisfaisants dans tous les contextes validés. Le système détecte plus de 93 % des interactions pour trois contextes sous les deux stratégies, un peu moins dans le contexte (K, extérieur) (respectivement 75 % et 81 %). La précision est supérieure à 81 % sous la stratégie de Référence, 77 % sous CRONOS.

Pour la catégorie antagoniste en mouvement (cf tableau 4.5), les résultats sont obtenus sur les mêmes séquences, prolongées de 10 minutes. Les nombres restent moins importants que pour la catégorie antagoniste, et les mesures de performances sont un peu moins bonnes, mais satisfaisantes pour les deux stratégies avec un rappel supérieur à 75 % et une précision supérieure à 72 % pour trois contextes. Le système a les performances les plus faibles dans le contexte (K, centre) sous les deux stratégies : la précision reste cependant au dessus de 50 %. Nous observons que les performances sur les deux catégories antagoniste et antagoniste en mouvement sont proches pour les deux stratégies.

Intersection	Origine	VP	FP	FN	Rappel	Précision
K	extérieur	60	4	20	75 %	94 %
K	centre	180	14	12	94 %	93 %
P	extérieur	68	16	5	93 %	81 %
P	centre	92	8	6	94 %	92 %
K	extérieur	29	1	7	81 %	97 %
K	centre	183	4	7	96 %	98 %
P	extérieur	104	31	4	96 %	77 %
P	centre	74	22	6	93 %	77 %

TABLE 4.4 – Résultats de validation de la détection des interactions de la catégorie antagoniste, sur 10 minutes (VP, Vrais Positifs ; FP, Faux Positifs ; FN, Faux Négatifs) en pointe sous la stratégie de Référence (en haut) et CRONOS (en bas). L'origine peut prendre deux valeurs, notée extérieur pour tronçon d'entrée et centre pour zone de stockage interne.

Pour la catégorie aval à l'arrêt, la validation pose problème sous les deux stratégies, différemment selon les zones de conflits. Tout d'abord dans l'intersection P, les détections sont assez abondantes, détectées essentiellement lors des phases de stockage de la seule zone aval de la zone de conflit P, dans laquelle le stockage déborde vite, et lors des phases de démarrage, pendant lesquelles les mobiles stockés dans la zone de conflit P peuvent être "rattrapés" par les mobiles venant d'une zone de stockage amont. Dans le contexte (P, extérieur), les interactions de la catégorie aval à l'arrêt consistent essentiellement en des rattrapages et les résultats ne sont pas bons : 29 % en précision. Les faux positifs sont largement majoritaires, du fait de formes d'arrêts erronées, en particulier qui ne disparaissent pas alors que la zone de conflit est vide des mobiles qui y étaient stockés. Dans le contexte (P, centre), les mesures semblent bonnes (94 % en rappel et 85 % en précision), mais correspondent uniquement à des interactions se déroulant lorsque tous les mobiles

Intersection	Origine	VP	FP	FN	Rappel	Précision
K	extérieur	45	2	12	79 %	96 %
K	centre	20	15	6	77 %	57 %
P	extérieur	36	12	2	95 %	75 %
P	centre	18	5	0	100 %	78 %
K	extérieur	24	1	7	77 %	96 %
K	centre	15	10	5	75 %	60 %
P	extérieur	31	12	2	94 %	72 %
P	centre	15	5	3	83 %	75 %

TABLE 4.5 – Résultats de validation de la détection des interactions de la catégorie antagoniste en mouvement, sur 20 minutes (VP, Vrais Positifs ; FP, Faux Positifs ; FN, Faux Négatifs) en pointe sous la stratégie de Référence (en haut) et CRONOS (en bas). L'origine peut prendre deux valeurs, notée extérieur pour tronçon d'entrée et centre pour zone de stockage interne.

se stockent dans la zone de conflit P. S'il se produit des interactions plus "intéressantes", elles sont diluées, ce qui ne permet pas de mesurer de différence significative entre les stratégies. La détection des interactions de la catégorie aval à l'arrêt se déroulant dans la zone de conflit P n'est pas fiable ou pas significative.

Dans l'intersection K, les interactions de la catégorie aval à l'arrêt sont très rares. Sur les 20 minutes utilisées pour les autres catégories, il n'y a pas eu une seule détection, ni un seul faux positif. Nous avons donc étudié un échantillon d'une heure de la stratégie de Référence (4 novembre 1998, de 8h à 9h, trafic de pointe), sur lequel il y avait quelques détections automatiques. Il en ressort les mêmes problèmes dans le contexte (K, extérieur) que dans le contexte (P, centre), avec des nombres beaucoup plus faibles : les interactions relevées se déroulent lors des phases d'arrêt et ne sont pas significatives. Les interactions de la catégorie aval à l'arrêt dans le contexte (K, centre) nous intéressent beaucoup car elles sont directement liées à la capacité de la stratégie à bien gérer la zone de stockage aval pour éviter que des mobiles soient stockés au milieu de la zone de conflit, avec lesquels les mobiles venant du centre peuvent entrer en interaction. Même sur une séquence d'une heure, les chiffres restent faibles : peu d'instantanés sont manqués, et le rappel est un peu supérieur à 50 %. C'est donc le seul contexte dans lequel nous nous intéressons aux interactions de la catégorie aval à l'arrêt.

4.4.3 L'indicateur de proximité

D'une part, l'indicateur de proximité est évalué par le système automatique en nombre de pavés. D'autre part, un expert observant des enregistrements vidéo des séquences de trafic n'est pas en mesure de distinguer autant de niveaux de proximité différents que le système. Parmi les valeurs que peut prendre l'indicateur de proximité pour la valeur de distance à la ligne de feu utilisée dans ces travaux, un expert est capable de distinguer trois niveaux de proximité. Nous avons mis ces trois niveaux en correspondance avec les valeurs calculées par le système. Il est en outre difficile pour l'expert de décider de

la valeur de l'indicateur pour certaines interactions lorsque cette valeur est proche de la "limite" entre les deux niveaux. Nous l'autorisons alors à ne pas se décider arbitrairement dans ce cas. La sortie du système sera correcte si elle correspond à un des deux niveaux entre lesquels l'expert hésite. Le problème se pose de la même façon pour l'indicateur de vitesse, et nous abordons plus longuement le sujet du jugement de l'expert dans le chapitre suivant.

Intersection	Origine	Taux de Bonne Classification	
		Référence	CRONOS
K	extérieur	68 %	74 %
K	centre	77 %	82 %
P	centre	85 %	90%
P	extérieur	90 %	83 %

TABLE 4.6 – Résultats de validation de l'indicateur de proximité sous les deux stratégies pour la catégorie antagoniste, sur 10 minutes en pointe.

Intersection	Origine	Taux de Bonne Classification	
		Référence	CRONOS
K	extérieur	76 %	80 %
K	centre	55 %	61 %
P	centre	81 %	76 %
P	extérieur	89 %	81 %

TABLE 4.7 – Résultats de validation de l'indicateur de proximité sous les deux stratégies pour la catégorie antagoniste en mouvement, sur 20 minutes en pointe.

Nous présentons ici les taux de bonne classification pour chaque contexte validé. Les tableaux 4.6 et 4.7 présentent de bons résultats respectivement pour les catégories antagoniste et antagoniste en mouvement proches sous les deux stratégies. Il apparaît que les résultats sont les plus faibles pour le lieu K. Nous ne savons pas à quoi les attribuer. Pour les interactions de la catégorie aval à l'arrêt, nous avons vu que leur détection pose des problèmes, hormis dans le contexte (K, centre). Il est impossible de valider l'indicateur de proximité pour cette catégorie, car l'expert n'arrive pas à distinguer des niveaux de sévérité différents selon cet indicateur (les valeurs calculées par le système sont majoritairement faibles, entre 0 et 2).

4.4.4 Remarques

Il apparaît qu'il n'y a pas de différences importantes sur les performances en détection des interactions et estimation de l'indicateur de proximité entre deux échantillons de chaque stratégie. Par contre, nous ne pouvons étudier les interactions de la catégorie aval à l'arrêt que dans un seul contexte. Les informations d'arrêt sont plus bruitées que nous le pensions et il est impossible d'adapter nos règles de façon à remédier à ce problème.

Nous avons relevé très peu d'erreurs entre catégories, i.e. une interaction détectée dans la mauvaise catégorie, ce qui peut par exemple résulter d'une erreur sur l'orig-

ine d'un mobile dans la zone de conflit. Nous avons remarqué sans les détailler ici de nombreuses difficultés liées aux conditions météorologiques. Par exemple lorsque le sol est mouillé, en conjonction avec du soleil ou les phares des véhicules, des formes apparaissent alors qu'il n'y a aucun mobile. Nous écartons dans la mesure du possible les échantillons avec de telles conditions météorologiques.

Nous remarquons que les performances de détection sont moins bonnes pour la catégorie antagoniste en mouvement que pour la catégorie antagoniste. Les détections d'interactions dans une même catégorie ont souvent lieu consécutivement, ou à des instants proches. Les erreurs de détection se produisent à la marge de ces périodes d'interactions d'une catégorie donnée. Les interactions de la catégorie antagoniste en mouvement se déroulent de façon plus sporadique que les interactions de la catégorie antagoniste, sur des périodes courtes, souvent sur un ou deux instants seulement, ce qui explique les différences de performance. Une piste alternative consisterait à étudier non plus les instants, mais ces périodes d'interactions.

4.5 Conclusion

Nous avons présenté une méthode de détection des interactions et de qualification des instants d'interaction selon l'indicateur de proximité, dont la pertinence est globalement validée sur les données que nous traitons.

Nous sommes déçus par les contre-performances de nos méthodes pour les interactions de la catégorie aval à l'arrêt, d'autant plus qu'elles sont pertinentes pour étudier certains aspects de l'impact des stratégies de régulation sur le risque des mobiles.

Les méthodes présentées ont leur limites. C'est pourquoi nous avons cherché à développer une méthode générique pour construire des modules capables d'évaluer tout indicateur de sévérité. Nous avons recours pour cela à des méthodes d'apprentissage à partir d'exemples fournis par un expert, dont le développement est décrit dans le chapitre suivant.

Résumé

- Le module de détection des interactions est construit par transfert de la connaissance explicite d'un expert, capable d'interpréter les données au niveau des zones. Nous pouvons décrire les interactions des catégories étudiées sous forme de règles.
- L'indicateur de proximité peut être simplement calculé comme un nombre de pavés identifiés par le premier module de détection des interactions.
- Les méthodes présentées dans ce chapitre sont validées sur nos données et donnent globalement de bons résultats, proches sous les deux stratégies. La détection des interactions de la catégorie aval à l'arrêt pose problème.

Find a bug in a program, and fix it, and the program will work today. Show the program how to find and fix a bug, and the program will work forever.

AI's Greatest Trends and Controversies,
IEEE Intelligent Systems 2000,
Oliver G. Selfridge

5

L'apprentissage de la sévérité des interactions

Sommaire du chapitre

5.1	Introduction à l'apprentissage	75
5.1.1	Système à base de règles et apprentissage	75
5.1.2	L'apprentissage artificiel	76
5.2	La problématique des indicateurs de sévérité	84
5.2.1	Les exemples	84
5.2.2	Les étiquettes de sévérité	86
5.2.3	Un algorithme incrémental pour traiter un flux de données	87
5.3	Apprentissage incrémental par sélection de données	92
5.3.1	Quels objectifs ?	92
5.3.2	Introduction à l'apprentissage actif	94
5.3.3	Sélection de données dans un flux	96
5.3.4	Critère d'arrêt	101
5.3.5	Combiner les hypothèses pour améliorer la stabilité des performances	103
5.4	Etudes expérimentales et validation	108
5.4.1	Problèmes classiques	111
5.4.2	L'indicateur de vitesse	119
5.4.3	Conclusion	127
5.5	Perspectives et problèmes ouverts	127

5.1 Introduction à l'apprentissage

5.1.1 Système à base de règles et apprentissage

Nous avons présenté dans le chapitre précédent la construction d'un système de reconnaissance basé sur quelques règles dédié à une tâche précise. Ce choix est justifié par sa simplicité et la validation de ses performances. Comme la citation en exergue nous le

rappelle, il a un inconvénient très important, résumé par la question suivante : comment adapter un système expert si la tâche évolue ? Par exemple, de nouveaux capteurs vidéos ou de nouvelles méthodes de traitement de l'image pourraient améliorer la définition spatio-temporelle des données. Il faudrait alors faire appel à un expert pour modifier le système mis en place et l'adapter à sa nouvelle tâche, voire l'abandonner pour construire un nouveau modèle. Nous défendons notre approche car elle est simple à mettre en œuvre. Les règles utilisées sont simples, peu nombreuses et ont été mises au point progressivement par adaptations successives à la tâche. Elles sont donc faciles à maintenir. L'adaptabilité d'un système à l'évolution de sa tâche est néanmoins une caractéristique très intéressante. Même si dans un système expert l'indépendance de la base de connaissance et du moteur d'inférence donne une certaine pérennité au système développé, au moins pour le moteur d'inférence, il semble nettement plus prometteur de mettre au point des méthodes, des algorithmes, qui s'adaptent au problème en limitant le volume de travail expert.

En ce qui concerne le second module d'estimation de la sévérité des interactions détectées, il est difficile d'explicitier des règles pour la plupart des indicateurs. La tâche nécessite d'interpréter les données au niveau de description des pavés. Surtout, nous voulons mettre au point une méthode générique valable pour tous les indicateurs de sévérité, qui pourrait être utilisée par des accidentologues travaillant sur de nouveaux indicateurs. C'est pourquoi nous avons travaillé sur une méthode générique d'apprentissage de l'estimation d'indicateurs de sévérité. A partir d'un ensemble de données évaluées par l'expert, le système devra approcher le jugement de l'expert pour traiter ensuite automatiquement d'autres données. Nous pouvons voir les deux modules de notre système sous l'angle du *transfert de connaissance* entre un expert et une machine. Le fonctionnement du premier module est entièrement défini par un expert, alors que le second module est seulement *guidé* par l'expert, à partir d'exemples de la tâche à accomplir.

Nous allons maintenant définir plus rigoureusement le domaine de l'apprentissage.

5.1.2 L'apprentissage artificiel

Introduction

Nos ouvrages de référence en apprentissage sont (Duda et Hart, 2000; Cornuéjols *et al.*, 2002). Nous utilisons l'expression *apprentissage artificiel*, traduction de l'expression anglaise consacrée "Machine Learning" défendue par (Cornuéjols *et al.*, 2002). Commençons par la définition de l'AAAI¹ et celle fournie dans l'avant-propos de (Cornuéjols *et al.*, 2002).

"L'apprentissage artificiel fait référence à la capacité d'un système à acquérir et intégrer de façon autonome des connaissances."²

"Cette notion englobe toute méthode permettant de construire un modèle de

1. American Association for Artificial Intelligence, <http://www.aaai.org>.

2. Machine learning refers to a system capable of the autonomous acquisition and integration of knowledge.

la réalité à partir de données, soit en améliorant un modèle partiel ou moins général, soit en créant complètement le modèle."

Voyons quelques exemples. La capacité d'apprentissage est une caractéristique des êtres vivants. De la naissance à l'âge adulte, les êtres vivants acquièrent de nombreuses capacités qui leur permettent de survivre dans leur environnement. L'apprentissage d'un langage, de l'écriture et de la lecture sont de bons exemples des capacités humaines, et des phénomènes mis en jeu : apprentissage par coeur, apprentissage supervisé par d'autres êtres humains, apprentissage par généralisation...

Une application classique de l'apprentissage artificiel est la reconnaissance de caractères manuscrits, tels qu'ils apparaissent sur une enveloppe. La difficulté tient au fait que la variété des formes rencontrée est infinie. L'apprentissage par coeur n'est pas possible, et il faut donc être capable de généraliser à partir d'un ensemble d'exemples de caractères.

Enfin, pour notre application, nous voulons estimer automatiquement dans les données disponibles un indicateur de sévérité caractérisant les interactions définies au chapitre 3 et détectées par le premier module de notre système décrit dans le chapitre 4. Pour cela, un expert regarde les enregistrements vidéos des interactions détectées par le premier module et fournit une information sur sa sévérité selon l'indicateur étudié.

Quelques mots d'Histoire...

L'apprentissage artificiel est une discipline jeune, à l'instar de l'Informatique et de l'Intelligence Artificielle. Il se situe au carrefour d'autres disciplines : philosophie, psychologie, biologie, logique, mathématique. Les premières études remontent à des travaux de statistique dans les années 1920. C'est après la seconde guerre mondiale que les premières expériences deviennent possibles. Se développent ensuite dans les années 1960 les approches connexionnistes avec des perceptrons, et la reconnaissance des formes. La mise en évidence des limites du perceptron simple arrête toutes les recherches dans ce domaine jusqu'à la renaissance dans les années 1980. Les années 1970 sont dominées par des systèmes mettant l'accent sur les connaissances, les systèmes experts, présentés dans le chapitre 4. Les limites de tels systèmes se font sentir dans les années 1980, pendant lesquelles a lieu le retour du connexionnisme avec un nouvel algorithme d'apprentissage. Les mathématiciens commencèrent parallèlement à s'éloigner du cadre cognitif de l'apprentissage pour envisager le problème sous l'angle de l'optimisation, pendant qu'apparaissaient de nouvelles méthodes comme les arbres de décision ou l'induction de programmes logiques. L'influence de la théorie statistique de l'apprentissage s'est réellement fait sentir dans les années 1990, avec l'ouvrage de Vapnik (Vapnik, 1998).

La discipline se partage entre travaux théoriques sur l'apprenabilité des problèmes et les propriétés des algorithmes, et une approche ingénieure plus portée sur la réalisation de méthodes d'apprentissage et de programmes informatiques. Nos travaux se placent dans la deuxième catégorie.

L'induction supervisée

L'*induction* est le processus par lequel on tire des lois de portée générale en partant de l'observation de cas particuliers. Ces lois peuvent soit juste permettre la prédiction sur une nouvelle observation, soit correspondre à une théorie générale du phénomène qui à la fois l'explique et permet de prédire. Nous n'abordons pas les autres formes d'apprentissage comme l'apprentissage non-supervisé, l'apprentissage par renforcement ou l'apprentissage par évolution simulée, et travaillons dans le cadre de l'induction supervisée.

Nous reprenons le formalisme de l'induction supervisée utilisé dans (Cornuéjols *et al.*, 2002). Un problème d'apprentissage est défini par différentes composantes, à commencer par les trois entités suivantes (cf figure 5.1) :

- L'*environnement* est supposé stationnaire et engendre des formes x (ou objets, exemples, données) tirées indépendamment et de manière identiquement distribuées³ suivant une distribution D_X sur l'espace X de représentation des objets.
- Un *expert* (ou oracle, superviseur), qui, pour chaque forme x retourne une réponse désirée ou étiquette u dans l'espace de supervision U selon une dépendance fonctionnelle entre X et U notée $F(x, u)$.
- Un *apprenant* capable de réaliser une fonction (non nécessairement déterministe) prise dans un espace de fonction H , appelée hypothèse h .

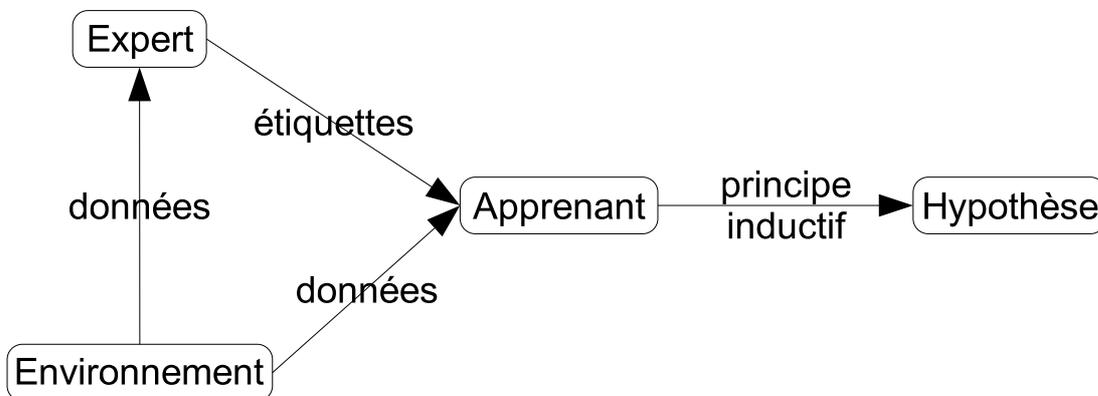


FIGURE 5.1 – Schéma fondamental de l'induction à partir d'un échantillon de données.

Il faut ensuite préciser la *tâche d'apprentissage*. L'apprenant cherche dans l'espace H une hypothèse h qui approxime au mieux la réponse de l'expert. Dans le cas de l'induction, nous mesurons une *perte* ou *coût* $l(u, h(x))$ pour chaque entrée x et réponse de l'expert u , évaluant le coût d'avoir pris la décision $y = h(x)$ quand la réponse désirée était u . La distance entre l'hypothèse h et la réponse de l'expert est définie par l'espérance de perte, ou *risque*, sur les situations possibles dans $X \times U$,

$$R_{\text{réel}}(h) = \int_{X \times U} l(u, h(x)) dF(x, u)$$

3. Les hypothèses sur la stationnarité de l'environnement, sur la distribution des données constituent le cadre classique de l'induction supervisée et simplifient cette présentation de l'induction supervisée.

Si, pour simplifier, nous supposons que la dépendance fonctionnelle entre une entrée x et son étiquette u prend la forme d'une fonction f appartenant à une famille de fonction F , il s'agit alors de trouver une hypothèse h proche de f au sens de la fonction de perte, en particulier dans les régions de l'espace des entrées X fréquemment rencontrées. Nous ne connaissons généralement pas ces régions a priori, mais nous disposons d'un ensemble d'apprentissage $S = \{(x_1, u_1), (x_2, u_2), \dots, (x_m, u_m)\}$ pour les estimer, et le problème de l'induction est de chercher à minimiser le risque réel inconnu à partir de l'observation de S .

Enfin, un *principe inductif* prescrit ce que doit vérifier la fonction h recherchée dans le but de minimiser le risque réel, en fonction à la fois de la notion de proximité évoquée ci-dessus, et donc de la fonction de perte l , de l'ensemble d'apprentissage observé S , et éventuellement d'autres critères. C'est un objectif idéal. Il faut le distinguer de la *méthode d'apprentissage*, ou *algorithme*, qui décrit une réalisation effective du principe inductif. Pour un principe inductif donné, il y a de nombreuses méthodes d'apprentissage qui résultent de choix différents pour régler les problèmes computationnels qui ne sont pas du ressort du principe inductif. Par exemple, un principe inductif appelé principe d'Occam⁴ prescrit de choisir l'hypothèse la plus simple compatible avec l'ensemble d'apprentissage. La méthode d'apprentissage doit alors spécifier comment chercher effectivement cette hypothèse, ou une hypothèse suboptimale s'il y a lieu, en satisfaisant certaines contraintes de réalisabilité comme des ressources computationnelles.

Cette formalisation est très générale. Le principe inductif peut intégrer des facteurs indépendants de l'adéquation aux données d'apprentissage et de natures très diverses, comme la simplicité de l'hypothèse produite par l'apprenant, sa compréhensibilité, son intelligibilité par un expert ou un utilisateur, le faible coût computationnel nécessaire à sa construction... Les critères du principe inductif sont relatifs à un observateur externe et au domaine étudié.

Le compromis biais-variance

Si nous faisons l'hypothèse que l'expert étiquette les données selon une fonction cible f dans une famille de fonctions F , l'induction supervisée se voit naturellement comme une tâche d'estimation de fonction à partir d'un échantillon de données. Nous supposons qu'il peut y avoir des informations d'étiquetage erronées, sous la forme d'un *bruit*, i.e. un écart mesurable entre l'étiquette proposée u et la véritable étiquette selon f . L'apprenant cherche la fonction h de H minimisant le risque réel selon une certaine fonction de perte. Nous appelons erreur totale l'erreur résultant de la conjonction des différentes erreurs entre la fonction cible f et l'hypothèse h . Elle se compose de trois termes.

- Rien ne permet a priori d'assurer l'égalité entre les espaces F et H . L'apprenant ne peut fournir qu'une hypothèse h^* minimisant le risque réel sur H , qui peut donc

4. Cet argument rhétorique classique, le "rasoir d'Occam", dû à Guillaume d'Occam (1288-1348), affirme qu'il ne sert à rien de multiplier les "entités" inutiles.

être différente de la fonction cible f . Il s'agit d'une *erreur d'approximation* souvent appelée *biais inductif* ou tout simplement *biais*.

- L'apprenant ne fournit en général pas h^* , mais calcule une hypothèse \hat{h} sur la base de l'ensemble d'apprentissage S . L'hypothèse \hat{h} pourra varier à l'intérieur d'un ensemble de fonctions dépendant de S . La distance entre h^* et \hat{h} est l'*erreur d'estimation*. Il peut être montré formellement qu'elle est une *variance* liée à la sensibilité du calcul de l'hypothèse \hat{h} en fonction de S .
- Finalement intervient le bruit sur l'étiquetage, à cause duquel l'apprenant reçoit un ensemble de données d'apprentissage relatif à la fonction bruitée $f_b = f + \text{bruit}$. Cette erreur intrinsèque complique la recherche de h^* .

De la description de cette erreur totale découle ce qui est appelé couramment le *compromis biais-variance*. Pour réduire le biais dû à la mauvaise adéquation de H par rapport à F , il faut accroître la richesse de H , ce qui va généralement de pair avec une augmentation de la variance. L'erreur totale, somme de termes variant en sens contraires, est donc difficile à diminuer. L'idéal serait d'avoir un bruit le plus faible possible, et de travailler avec un espace d'hypothèses H restreint pour réduire la variance, mais suffisamment bien informé pour recouper F . Cela suppose des connaissances a priori sur la tâche.

Quelques principes inductifs

Il n'y a pas de principe inductif unique ou idéal. Comment extraire, à partir des données, une régularité qui ait des chances d'avoir une pertinence pour l'avenir ? Différents principes inductifs "raisonnables" ont été proposés.

Un premier principe inductif indique de choisir l'hypothèse minimisant le risque empirique, i.e. la perte moyenne mesurée sur l'échantillon d'apprentissage S :

$$R_{emp}(h) = \frac{1}{m} \sum_{i=1}^m l(u_i, h(x_i))$$

L'idée intuitive est que l'hypothèse qui s'accorde le mieux aux données, en supposant que celles-ci soient représentatives, est une hypothèse qui décrit correctement le monde en général. Ce *principe de minimisation du risque empirique* a été souvent implicitement le principe utilisé en intelligence artificielle depuis l'origine, dans l'approche connexionniste par exemple. Une hypothèse cohérente avec les données est une hypothèse de risque empirique nul.

Un second principe inductif courant consiste à choisir l'hypothèse la plus probable étant donné l'échantillon d'apprentissage. C'est le *principe de décision bayésienne*. Selon ce principe, il est possible de définir une distribution de probabilité sur l'espace des hypothèses H et que la connaissance du domaine préalable à l'apprentissage peut s'exprimer sous la forme d'une distribution de probabilité a priori sur les hypothèses. L'échantillon d'apprentissage est alors considéré comme une information modifiant la distribution de probabilité sur H . Est choisie l'hypothèse la plus probable a posteriori

(principe du maximum de vraisemblance ou du maximum a posteriori), ou une hypothèse composite résultant de la moyenne des hypothèses pondérées par leur probabilité a posteriori (vraie approche bayésienne).

Un troisième principe inductif consiste à choisir l'hypothèse qui comprime au mieux les informations contenues dans l'échantillon d'apprentissage. C'est le *principe de compression d'information*. L'idée est d'éliminer les redondances présentes dans les données afin d'extraire les régularités sous-jacentes permettant la description économique du monde. Il est supposé que les régularités découvertes dans l'échantillon d'apprentissage sont valides au-delà et s'appliquent au monde en général.

L'examen du compromis biais-variance montre que l'espérance de risque (le risque réel) dépend à la fois du risque empirique mesuré sur l'échantillon d'apprentissage et de la "capacité" ou "richesse" de l'espace des fonctions hypothèses. Puisqu'il n'est possible de mesurer que le risque empirique, l'idée consiste à essayer d'évaluer le risque réel en corrigeant le risque empirique, i.e. l'adaptation aux données, forcément optimiste par rapport au risque réel, par un terme de pénalisation ou de régularisation correspondant à une mesure de la capacité de l'espace d'hypothèses H^5 . Ces méthodes sont complémentaires des premiers principes inductifs présentés (cf (Cornuéjols *et al.*, 2002) pour plus de détails).

Analyse de l'apprentissage

Il est possible d'étudier sous quelles conditions l'apprentissage est possible, en faisant des hypothèses supplémentaires sur ce qui est attendu du système d'apprentissage. Les principes inductifs présentés ne conduisent pas à la même analyse. Nous renvoyons par exemple à (Kulkarni *et al.*, 1999) pour plus de détails⁶.

Le principe de minimisation du risque empirique conduit à une *analyse dans le pire des cas*, en utilisant un théorème de convergence du risque empirique vers le risque réel, qui fait intervenir la pire hypothèse possible. Supposant que rien n'est connu a priori sur l'environnement, la distribution des formes d'apprentissage, la fonction cible..., cette analyse fournit des garanties tellement fortes qu'elles sont souvent éloignées des situations d'apprentissage réelles.

Le point de vue bayésien est indissociable d'une *analyse en cas moyen*, mesurant une espérance de performance. Elle suppose qu'il existe a priori une distribution sur l'espace de représentation des formes d'apprentissage ainsi que sur l'espace des fonctions cibles possibles, exprimant la connaissance a priori sur le problème. Il est cependant difficile d'obtenir des solutions analytiques dans ce cas et les approximations ôtent une partie de l'intérêt de ces méthodes.

Nous avons présenté pour l'instant un cadre pour l'induction supervisée transformant un problème d'apprentissage en un problème d'optimisation spécifiant un critère

5. Le principe de longueur de description minimale permet de pénaliser la complexité d'une hypothèse.

6. Le site de G. Lugosi propose de nombreux articles et états de l'art : <http://www.econ.upf.es/~lugosi/>

que doit optimiser l'hypothèse idéale. La plupart des méthodes d'apprentissage peuvent être vues comme des manières de spécifier l'espace des hypothèses à considérer ainsi que la technique d'exploration de cet espace pour y trouver la meilleure hypothèse. Cette approche est puissante, mais très éloignée d'un grand nombre de cadres plus "réalistes" comme le notre. D'une part, les données sont disponibles de façon aléatoire, ce qui exclut les situations d'apprentissage organisé ou bienveillant. D'autre part, l'apprenant est solitaire, complètement passif, attend les données, et ne fait en général rien avant de disposer de leur totalité. Sont exclus les apprentissages continus, collaboratifs, avec une évolution de l'apprenant, les apprentissages dans les environnements non stationnaires. L'apprenant cherche à être performant en moyenne (optimisation de l'espérance de risque), mais pas vraiment à identifier le concept cible, en consacrant par exemple ses ressources aux régions de l'espace dans lesquelles la fonction cible présente de fortes variations et moins aux autres régions.

Certaines de ces alternatives sont déjà étudiées, comme l'apprentissage actif que nous présentons dans la suite. D'autres n'ont pas encore de cadre bien défini. Dans le cadre d'un apprentissage collaboratif, il est par exemple difficile de déterminer la frontière entre la bienveillance, celle d'un professeur par exemple, et la collusion, dans le cas où l'expert transmettrait directement la solution.

Evaluation de l'apprentissage

Nous disposons d'un ensemble d'exemples et d'un algorithme d'apprentissage dont nous pouvons régler certains paramètres. Cet algorithme retourne une hypothèse. Comment évaluer la performance de cette hypothèse pour l'utiliser ensuite en prédiction ? Nous avons vu qu'il existe différents critères pour la juger. Suffit-il en particulier de faire confiance au principe de minimisation du risque empirique et de se fonder sur la performance mesurée sur l'échantillon d'apprentissage ? Il faut prendre des précautions, car le risque empirique est intrinsèquement optimiste et n'est pas forcément un bon indicateur de la vraie performance, le risque réel. Tandis que le risque empirique continue de diminuer au fur et à mesure de la prise en compte d'information, le risque réel diminue également dans un premier temps, puis augmente de nouveau après un certain stade, au-delà duquel il n'y a plus de corrélation entre le risque empirique et le risque réel. C'est le phénomène de *surapprentissage*.

L'analyse de l'apprentissage ne nous aide pas beaucoup car elle fournit des bornes de différence entre risque réel et risque empirique souvent éloignées de ce qui est observé. Les résultats sont souvent détaillés en prenant la fonction de perte l suivante, dite "0-1",

$$l(u_i, h(x_i)) = \begin{cases} 0 & \text{si } u_i = h(x_i) \\ 1 & \text{si } u_i \neq h(x_i) \end{cases}$$

Dans ce cas, le risque réel mesure la probabilité de mauvaise classification. En utilisant la matrice de confusion, qui contient à la position (i, j) le nombre d'objets de la classe c_i

catégorisés par l'hypothèse h dans la classe c_j , noté $M_{i,j}$, avec N_C le nombre de classes (cf partie 4.4), nous avons

$$R_{emp}(h) = \frac{\sum_{1 \leq i \leq N_C, 1 \leq j \leq N_C, i \neq j} M_{i,j}}{\sum_{1 \leq i \leq N_C, 1 \leq j \leq N_C} M_{i,j}} = 1 - \text{Taux Bonne Classification}$$

Nous avons aussi défini dans la partie 4.4 les mesures de rappel et précision pour une classe à partir de la matrice de confusion dans le cas de cette fonction de perte.

La méthode la plus simple pour estimer la qualité objective d'une hypothèse h est de couper l'ensemble des exemples étiquetés S en deux ensembles indépendants : le premier, l'ensemble d'apprentissage, noté S_A , est utilisé pour construire h et le second, l'ensemble de test, noté S_T , sert à mesurer sa qualité. Ils vérifient $S = S_A \cup S_T$ et $S_A \cap S_T = \emptyset$. Le risque empirique de h sur S_T (et non sur S_A) est une estimation non-biaisée du risque réel d'erreur de h , noté $\hat{R}_{réel}(h)$. Des considérations statistiques indiquent que la précision de l'estimation ne dépend que du nombre t d'éléments de S_T et de $\hat{R}_{réel}(h)$ (cf (Cornuéjols *et al.*, 2002) pour le calcul des intervalles de confiance). En particulier, plus t augmente, plus l'estimation est précise. Cependant, S étant souvent limité, et les deux ensembles indépendants, il faut trouver un compromis entre avoir l'ensemble S_A le plus grand possible pour apprendre, et l'ensemble S_T le plus grand possible pour évaluer la qualité de l'apprentissage. Si les données sont peu nombreuses, il faut se tourner vers d'autres méthodes.

L'une des méthodes les plus utilisées est la *validation croisée*. Elle consiste à partitionner l'ensemble des données étiquetées S en N sous-ensembles S_i de tailles égales. Chaque sous-ensemble est utilisé en test pour une hypothèse apprise sur les $N - 1$ sous-ensembles restants. Chaque exemple de S est donc utilisé en test une fois, et comptabilisé dans une matrice de confusion, à partir de laquelle peuvent être calculées les mesures de performances comme le risque empirique, le rappel et la précision. Ce risque est une estimation non-biaisée du risque réel. N prend le plus souvent une valeur entre 5 et 10. L'avantage est d'utiliser une grande partie des données pour apprendre, au prix d'une répétition de cet apprentissage N fois. Il n'est de plus pas évident de choisir quelle hypothèse finalement utiliser. (Cornuéjols *et al.*, 2002) indique que la meilleure méthode est de refaire un apprentissage sur S . Une autre solution consiste à combiner les N hypothèses construites. Le "leave-one-out" consiste comme son nom l'indique à pousser à l'extrême la méthode de validation croisée, en prenant $N = |S|$.

En face d'un problème d'apprentissage, il faut choisir les différents ingrédients, la mesure de performance, l'espace des hypothèses, l'algorithme d'apprentissage, les paramètres de l'algorithme. Il faut se méfier de l'approche consistant à évaluer systématiquement les choix en faisant appel d'une façon ou d'une autre à un ensemble de test. A force de vouloir minimiser le risque sur cet ensemble, nous risquons d'adapter étroitement les choix à cet ensemble, et de nous éloigner d'une diminution du risque réel, comme dans le cas du surapprentissage. Il faut alors prévoir un ensemble supplémentaire de *validation* pour évaluer la performance réelle des choix. Un tel ensemble est aussi utile pour déterminer une condition d'arrêt de certains algorithmes d'apprentissage, comme pour

les réseaux de neurones. Selon l'application il est aussi possible d'utiliser d'autres fonctions de perte. Nous précisons plus loin comment nous évaluons la performance dans notre cas.

5.2 La problématique des indicateurs de sévérité

Nous présentons maintenant notre problème d'apprentissage. Nous voulons constituer un module d'estimation automatique de la sévérité des interactions détectées par le premier module de notre système dans une image à un instant t . Les informations sur la sévérité sont fournies par un expert à partir des enregistrements vidéos des scènes de trafic correspondant aux données. Nous travaillons sur l'*indicateur de vitesse* défini dans la partie 3.3.2.

L'indicateur de vitesse se simplifie comme l'indicateur de proximité. Pour les interactions des catégories *aval à l'arrêt* et *antagoniste à l'arrêt*, le différentiel de vitesse se ramène à la vitesse du mobile en mouvement dans la zone de conflit. Dans le cas des interactions de la catégorie *antagoniste en mouvement*, nous avons fait l'hypothèse pour l'indicateur de proximité que la plupart des mobiles dans la zone de stockage antagoniste ont une vitesse faible, et constaté que ces vitesses faibles sont impossibles à estimer finement. Nous négligeons donc cette vitesse et l'indicateur de vitesse se calcule pour toutes les catégories comme la vitesse du mobile en mouvement dans la zone de conflit. A chaque seconde, l'indicateur de vitesse pour un contexte donné se définit alors comme la vitesse moyenne des mobiles en interaction dans ce contexte en mouvement dans la zone de conflit. Ces mobiles sont supposés avoir un comportement homogène.

5.2.1 Les exemples

Le premier élément dans un problème d'apprentissage est la description des données, et le choix d'un espace de représentation des données. Les données s'écrivent souvent comme un ensemble de d attributs, $x = (x_1, x_2, x_3, \dots, x_d) \in X$. Ces attributs peuvent prendre valeur dans des ensembles de natures très différentes. Les plus courants sont les attributs numériques et nominaux, i.e. appartenant à un ensemble fini et non ordonné. Pour estimer la sévérité des interactions, il est nécessaire de traiter nos données au niveau de description des pavés. Un exemple est donc une image ou une partie d'image, i.e. un ensemble de pavés. Chaque attribut correspond à un pavé et peut prendre six valeurs non ordonnées (cf partie 3.2.3). Tous les attributs sont donc nominaux.

Nous précisons la constitution des exemples pour l'estimation de l'indicateur de vitesse. Pour tout contexte (lieu, origine, catégorie), le premier module indique s'il y a interaction ou pas à l'instant t . Le second module estime la sévérité des interactions de chaque contexte. L'indicateur de vitesse des interactions de chaque contexte (lieu, origine) est le même pour toutes les catégories. Il est donc fonction uniquement du lieu et de l'origine de l'interaction. Nous faisons l'hypothèse que les informations nécessaires dans chaque contexte (lieu, origine) sont contenues dans les états des pavés de la zone de conflit con-

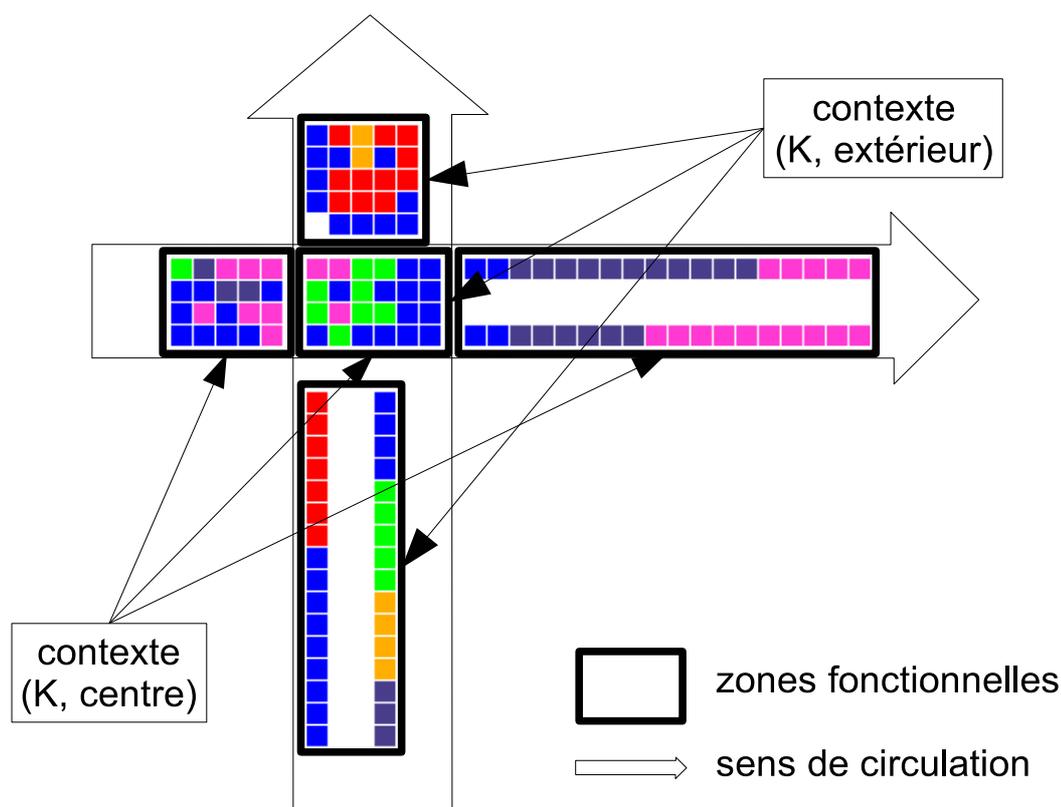


FIGURE 5.2 – Illustration des zones constituant les exemples traités par le module d'estimation de l'indicateur de vitesse selon le contexte (lieu, origine), ici autour de la zone de conflit K.

cernée (le lieu), et les zones amont ou aval. Pour chaque zone de conflit, cinq zones sont donc concernées⁷. Lors du début de nos travaux, nous avons fait différents essais pour choisir les zones constituant les exemples. Il s'est révélé que pour un contexte (lieu, origine) donné, il était possible de limiter les zones prises en compte à trois zones, la zone de conflit, la zone origine de l'interaction et la zone aval dans l'alignement de la zone origine (cf figure 5.2). Nous avons constaté que les performances d'apprentissage étaient similaires avec ces trois zones ou avec les cinq zones possibles. C'est compréhensible car il n'y a pas d'information dans la zone de stockage antagoniste, et peu dans la zone aval écartée. Cette zone sera empruntée par les mobiles qui tournent à gauche, dont la vitesse sera faible.

Il est possible de faire des pré-traitements des données, comme la sélection d'attributs, car certains pavés n'apportent pas ou peu d'information dans les exemples utilisés dans nos expériences. Nous avons cependant choisi de ne pas pré-traiter les données pour des raisons liées au cadre d'apprentissage en ligne dans lequel nous nous plaçons et qui est décrit dans la suite. Les exemples sont donc des vecteurs d'attributs nominaux prenant six valeurs, de longueur variable selon le contexte (lieu, origine) des interactions traitées.

⁷. Hormis pour zone de conflit P qui incorpore sa seule zone aval, pour laquelle trois zones seulement sont donc concernées.

Cet aspect est un argument de plus pour traiter les interactions indépendamment selon leur contexte. Des hypothèses différentes doivent être construites pour chaque contexte.

5.2.2 Les étiquettes de sévérité

Il faut aussi définir l'espace de supervision U , espace des étiquettes ou réponses désirées u associées à chaque exemple x . Il peut être de différentes natures, comme les espaces des attributs. Si l'étiquette est numérique, il s'agit d'un problème de régression. Si l'étiquette est nominale, il s'agit d'un problème de classification. Dans notre travail, l'étiquette d'un exemple est un indicateur de sévérité par contexte qualifiant une ou plusieurs interactions détectées dans une image à un instant t dans ce contexte. Les étiquettes sont fournies par un expert. En tant que telles, nos étiquettes ont des propriétés particulières.

Un expert n'est pas capable de fournir des informations d'une grande finesse. Son jugement est *imprécis*. Il ne distingue qu'un petit nombre de niveaux de sévérité. L'étiquette de sévérité fournie par l'expert est donc ordinale, i.e. elle appartient à un ensemble ordonné sur lequel il n'est pas possible de définir une distance (comme des médailles d'or, d'argent et de bronze). Nous pouvons parler pour ces niveaux de sévérité de *classes ordonnées*. L'une des méthodes les plus utilisées pour décrire des données imprécises est la logique floue (Bouchon-Meunier, 1994). Nous reprenons l'exemple et la modélisation de (Rick, 2001). Dans le raisonnement humain, les frontières nettes entre deux classes sont rares. Il semble beaucoup plus naturel de raisonner avec des frontières graduelles. Si nous demandons à un expert de classer des fraises selon leur degré de sucre dans quelques classes comme "pas du tout sucrée", "légèrement sucrée", "sucrée" et "très sucrée", et si nous regardons son classement par rapport au degré de sucre mesuré de chaque fraise, nous constatons que les fraises ne sont pas classées dans l'ordre strictement croissant, mais qu'au contraire il existe des zones de transition où les fraises de classes proches sont mélangées. Le phénomène est le même avec nos données et les indicateurs de sévérité, en particulier l'indicateur de vitesse.

Nous pouvons utiliser des fonctions d'appartenance pour décrire les classes identifiées par l'expert, par exemple en choisissant les zones où des exemples de classes différentes sont mélangés comme les zones de transition de fonctions d'appartenance trapézoïdales (cf figure 5.3). Ces fonctions d'appartenance sont subjectives, nécessitent un certain temps pour se former, et peuvent évoluer dans le temps. Les étiquettes de sévérité fournies par l'expert appartiennent à un ensemble de classes ordonnées modélisées par des sous-ensembles flous aux frontières graduelles.

A l'imprécision du jugement de l'expert s'ajoute son *incertitude*. L'expert attribue les exemples situés dans les zones de transitions graduelles entre classes tantôt à une classe, tantôt à l'autre, de façon parfois arbitraire. Il hésite. Pour éviter un choix arbitraire, que nous pensons néfaste pour l'apprentissage car aléatoire, l'expert indique que l'exemple peut appartenir aussi bien à l'une qu'à l'autre classe. Nous parlons dans ce cas d'étiquette "floue". Cette méthode rentre dans le cadre de l'"apprentissage avec étiquettes

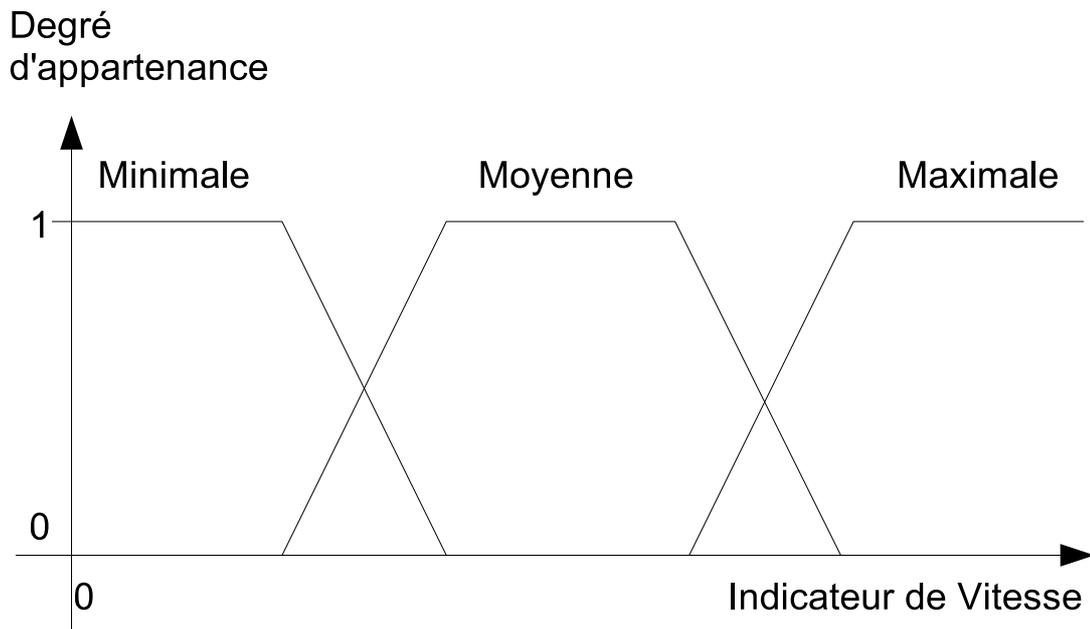


FIGURE 5.3 – Illustration de fonctions d'appartenance pour décrire les classes de sévérité.

multiples", dans lequel les exemples sont fournis avec un ensemble d'étiquettes possibles (Jin et Ghahramani, 2003).

Nous voulons estimer la sévérité des interactions par contexte, i.e. pour chaque exemple x le système retourne un niveau de sévérité $y = h(x)$. Soit Y l'ensemble des niveaux (classes) de sévérité définies par l'expert. Nous pouvons alors écrire

$$U = Y \cup \{\text{étiquettes floues}\}$$

Pour N_C classes ordonnées ($N_C = |Y|$), l'expert pourra utiliser $N_C - 1$ étiquettes floues correspondant aux transitions entre les classes. Dans nos expériences sur l'indicateur de vitesse, nous avons typiquement $N_C = 3$, i.e. une classe de valeurs minimales (MIN), une classe de valeurs maximales (MAX), et une classe intermédiaire, moyenne (MOY), comme dans l'exemple de la figure 5.3. Les étiquettes floues sont notées MIN-MOY et MOY-MAX.

La supervision de l'expert, de nature hétérogène, a des caractéristiques particulières, différentes du cadre classique de l'apprentissage. Nous devons proposer des méthodes d'apprentissage qui tirent le meilleur parti de ces informations.

5.2.3 Un algorithme incrémental pour traiter un flux de données

Nos données ont un caractère séquentiel. Même si nous travaillons sur des données enregistrées, les images ont été générées toutes les secondes en temps réel lors des expériences. Ces données ont donc un ordre naturel. De plus, l'expert juge la sévérité des interactions à partir des enregistrements vidéo, stockés sur bandes VHS. Cela impose

des contraintes sur la navigation dans les données. Il est plus facile d'accéder aux données séquentiellement pour les étiqueter. Nous voulons aussi être en mesure d'effectuer l'apprentissage du système en temps réel. Tous ces éléments nous placent donc dans un *cadre séquentiel* ou *en ligne* ("online") dans lequel les données sont présentées à l'apprenant séquentiellement, par groupe ou individuellement, en un *flux de données*. Le cadre opposé, dans lequel l'ensemble des données est disponible pour l'apprenant, est dit hors ligne ("offline" ou "batch").

En outre, il est probable que les données "changent" au cours du temps, qu'il y ait changement de concepts ("concept drift"). Cela signifie que pour diverses raisons (par exemple les conditions météorologiques, lumineuses, le temps d'ensoleillement, le trafic...) les exemples, leurs étiquettes et leur relation, ont évolué tout au long de l'expérience, sur huit mois consécutifs. Il est nécessaire d'envisager des méthodes de mise à jour de l'hypothèse pour suivre les évolutions de la fonction cible. La plupart des organismes naturels, les organisations sociales et les institutions, mais aussi certains systèmes artificiels, ne peuvent survivre que s'ils apprennent en permanence et si leur performance tout au long de leur existence est correcte.

Etat de l'art des algorithmes incrémentaux

Un algorithme d'apprentissage capable de traiter un flux de données, i.e. dans lequel l'apprenant doit mettre à jour l'hypothèse après chaque nouvel exemple ou ensemble d'exemples, est dit *incrémental*⁸. Un algorithme incrémental peut aussi être utilisé hors ligne, lorsque tous les exemples sont disponibles. Quel que soit le cadre, un algorithme incrémental a les caractéristiques suivantes (Holmes *et al.*, 2004; Polikar *et al.*, 2001) :

- Il permet d'apprendre en une seule passe sur les données.
- A chaque étape ("trial"), il permet de mettre à jour l'hypothèse en fonction de nouvelle(s) donnée(s), sans accéder aux données originelles à partir desquelles l'hypothèse a été précédemment construite. Il est sous-entendu qu'il n'est pas possible de stocker au fur et à mesure tous les exemples.
- (Sutton et Whitehead, 1993) distingue deux niveaux d'incrémentalité. Les algorithmes *strictement incrémentaux* pour lesquels la mémoire et les calculs nécessaires au traitement de chaque exemple n'augmentent pas en fonction du nombre d'exemples d'apprentissage. Par opposition, les algorithmes *faiblement incrémentaux* nécessitent un peu de mémoire et/ou de calcul supplémentaires à chaque traitement d'un exemple⁹. Un exemple d'algorithme faiblement incrémental est ID5 (Utgoff, 1989) et l'algorithme des plus proches voisins. L'algorithme des classifieurs bayésiens (John et Langley, 1995) est strictement incrémental.

8. Par abus de langage, un algorithme incrémental est parfois appelé algorithme en ligne ou "online"

9. Un algorithme non-incrémental peut être utilisé en ligne en ajoutant les nouvelles données aux précédentes, et en ré-apprenant, pour une durée de temps forcément limitée. C'est le "pire" des algorithmes faiblement incrémentaux. La plupart des méthodes faiblement incrémentales ou non-incrémentales peuvent devenir strictement incrémentales en limitant par exemple l'ensemble d'apprentissage à une fenêtre d'un certain nombre des derniers exemples vus.

- Un point important est la dépendance de l'hypothèse produite à l'ordre de présentation des données d'apprentissage. La plupart des algorithmes incrémentaux y sont sensibles. L'algorithme des classifieurs bayésiens est un exemple d'algorithme incrémental insensible à l'ordre de présentation des données. Ce problème ne se pose que dans le cadre hors ligne.

Des contraintes supplémentaires peuvent s'ajouter, comme des contraintes temps réel ou le traitement de l'évolution temporelle des données. (Polikar *et al.*, 2001) aborde le sujet sous l'angle du compromis entre l'apprentissage de nouvelles informations et la préservation de la connaissance précédemment acquise, soit le *dilemme stabilité-plasticité*. Il s'agit de trouver un équilibre entre un algorithme trop stable qui n'apprend plus, et un algorithme trop souple, "plastique", qui oublie au fur et à mesure qu'il apprend. Parmi les réseaux de neurones, les perceptrons multi-couches sont un bon exemple d'algorithme incrémental trop plastique, alors que ARTMAP réussit un bon compromis stabilité-plasticité, mais est malheureusement difficile à régler (Polikar *et al.*, 2001). Un algorithme d'apprentissage incrémental a de plus l'avantage de pouvoir être stoppé à tout instant et de retourner une solution : l'hypothèse après sa dernière mise à jour¹⁰. Une version incrémentale d'un algorithme d'apprentissage non-incrémental est dite sans perte ("lossless") si pour un même ensemble d'apprentissage, cette version incrémentale produit la même hypothèse que la version non-incrémentale. (Lee et Clyde, 2004) présente une version incrémentale sans perte de l'algorithme de Bagging¹¹, à la différence de celle présentée dans (Oza et Russell, 2001).

Il est courant dans le cadre hors ligne de mettre en œuvre un pré-traitement des données, comme la sélection d'attribut ou la discrétisation des attributs numériques nécessitée par des algorithmes qui ne traitent que des attributs nominaux. Dans le cadre en ligne, puisque la distribution des données n'est généralement pas connue et peut évoluer au cours du temps, ce type de traitement des données peut difficilement être employé a priori avant apprentissage au risque d'handicaper gravement l'algorithme d'apprentissage utilisé. Ces techniques doivent s'adapter au cours du temps et être intégrées dans l'algorithme incrémental. Nous ne traitons pas ce problème et utilisons donc les exemples tels qu'ils ont été définis précédemment, sans traitement particulier.

Les algorithmes d'apprentissage incrémentaux possèdent des qualités très importantes. La plus importante, citée en exergue de ce chapitre, est l'adaptabilité. L'apprentissage incrémental est essentiel si nous voulons obtenir des systèmes qui apprennent et non simplement des systèmes appris¹². Il n'y a dans ce cas virtuellement plus de distinction entre les phases d'apprentissage et d'utilisation de l'hypothèse en prédiction¹³. Les robots, la surveillance de systèmes comme internet et la modélisation en temps réel

10. Un algorithme incrémental est "anytime". Un algorithme anytime peut être stoppé à tout instant et doit fournir une solution, dont la qualité est croissante dans le temps (Dietterich, 1998).

11. Nous parlons plus loin des méthodes de combinaison d'hypothèses dont fait partie cet algorithme.

12. "Online learning is essential if we want to obtain learning systems as opposed to merely learned ones" (Sutton et Whitehead, 1993).

13. Il n'y a plus de distinction entre les phases d'apprentissage et d'utilisation de l'hypothèse en prédiction tant que des données *étiquetées* sont disponibles.

de l'utilisateur sont des applications qui doivent s'adapter à des environnements qui ne sont pas connus à l'avance et évoluent en permanence (Ralaivola et d'Alché Buc, 2001; Bredeche *et al.*, 2003). En outre, les algorithmes incrémentaux sont indispensables pour le traitement de grosses quantités de données, une des problématiques de l'apprentissage artificiel les plus importantes selon (Dietterich, 1998). Les multiples passes sur l'ensemble des données requises par la plupart des algorithmes non-incrémentaux rendent leur coût computationnel prohibitif, sans parler de l'explosion potentielle de la taille des hypothèses produites par certains algorithmes (Oza et Russell, 2001). Pour ces raisons, les méthodes incrémentales sont aussi étudiées en fouille de données (Kerdprasop et Kerdprasop, 2003; Ma *et al.*, 2004).

L'un des algorithmes incrémentaux les plus anciens et les plus cités est un algorithme d'apprentissage par arbre de décision, l'algorithme ID5 (Utgoff, 1989), version incrémentale avec perte de ID3, l'algorithme bien connu de R. Quinlan. D'autres types d'arbres de décision peuvent être construits incrémentalement comme (Utgoff *et al.*, 1997) et récemment (Holmes *et al.*, 2004). (Domingos et Hulten, 2000) s'intéresse particulièrement au traitement de gros volumes de données en ligne. Pour leur propriétés théoriques ont été développés des algorithmes simples utilisant des poids sur un ensemble d'"experts" avec mise à jour multiplicative, comme "Winnow" (séparateur linéaire) (Littlestone, 1988) et l'algorithme de "weighted majority" (Littlestone et Warmuth, 1994). Ces algorithmes sont étudiés dans le cadre des modèles avec "nombre d'erreurs" ou "perte relative", que nous voyons dans la partie suivante (Blum, 1998). L'algorithme des classifieurs bayésiens naïfs, i.e. supposant que les attributs sont indépendants, est incrémental (John et Langley, 1995). Malgré leur hypothèse simplificatrice, ils montrent des performances étonnamment bonnes sur un grand nombre de problèmes (Domingos et Pazzani, 1997). Des modèles plus complexes, toujours avec des algorithmes incrémentaux, se limitant à des dépendances entre les attributs deux à deux, ont été développés (Webb *et al.*, 2005). Des algorithmes non-incrémentaux connus ont été étendus dans des versions incrémentales, parfois sans perte, pour profiter de leurs propriétés en ligne : les machines à support de vecteurs ("SVM") (Ho et Wechsler, 2004; Ralaivola et d'Alché Buc, 2001), des méthodes de combinaison d'hypothèses comme Bagging et Boosting (Oza et Russell, 2001; Lee et Clyde, 2004), appliquées aux réseaux de neurones pour un meilleur compromis stabilité-plasticité (Polikar *et al.*, 2001).

Dans ce travail, nous n'avons pas mis en œuvre de méthodes pour traiter l'évolution des concepts. Nous présentons à la fin du chapitre des algorithmes incrémentaux pour proposer des solutions à cet aspect du problème.

Evaluation de l'apprentissage dans le cadre en ligne

Les critères généraux d'évaluation de l'apprentissage décrits précédemment privilégient le cadre hors ligne, dans lequel la performance n'est mesurée qu'après apprentissage. C'est très restrictif. S'il y a apprentissage permanent, la performance doit être correcte tout le temps, et pas mesurée seulement une fois à la fin. Il est donc important de

définir des mesures de performances qui puissent s'appliquer tout au long de la trajectoire des états suivie par l'apprenant afin de traduire la qualité des décisions prises, alors que la séquence des données peut ne pas être bornée.

Pour autant, les expériences menées sur des algorithmes incrémentaux traitent toujours une séquence finie de données, en particulier parce qu'obtenir les étiquettes des exemples a un coût. Dans la plupart de ces travaux, un ensemble de test indépendant de la séquence d'apprentissage est utilisé pour évaluer les performances des hypothèses produites tout au long de l'apprentissage (Polikar *et al.*, 2001; Oza et Russell, 2001; Kerdprasop et Kerdprasop, 2003; Lee et Clyde, 2004; Holmes *et al.*, 2004; Webb *et al.*, 2005)¹⁴. Il est en outre toujours possible d'évaluer des algorithmes d'apprentissage incrémentaux dans un cadre hors ligne, i.e. de s'intéresser uniquement à la performance à la fin de la séquence d'apprentissage, ordonnée naturellement ou aléatoirement, et d'utiliser les autres méthodes comme la validation croisée. Il peut être alors intéressant d'utiliser aussi des algorithmes non-incrémentaux comme "points de comparaison" (Ralaivola et d'Alché Buc, 2001).

D'autres travaux, pour la plupart théoriques, s'intéressent à des séquences infinies. Nous reprenons (Cornuéjols *et al.*, 2002), qui lui-même s'appuie sur (Littlestone, 1988; ?; Littlestone et Warmuth, 1994; Blum, 1998; ?), références auxquelles s'ajoutent (Kalai et Vempala, 2003; ?). Deux types de scénario ont été explorés. Dans le cadre de l'apprentissage incrémental avec *nombre d'erreurs* ("mistake bound"), on cherche à savoir combien d'erreurs nous pouvons être amenés à faire dans le pire des cas, i.e. la pire tâche d'apprentissage avec la séquence la plus désavantageuse. A chaque étape, un exemple est fourni à l'apprenant, qui doit prédire son étiquette, avant de recevoir la vraie. L'apprenant est pénalisé pour chaque erreur et le but est de minimiser le nombre d'erreurs pendant l'apprentissage, avec des ressources limitées. Typiquement, la présentation des exemples est contrôlée par un adversaire. Dans le cadre de l'apprentissage incrémental avec *perte relative* ("relative loss bound"), nous nous intéressons aux propriétés de la prédiction d'une séquence, et non d'une population de séquences générée par un modèle probabiliste. La mesure de performance d'un algorithme ne peut plus alors se faire dans l'absolu, mais par comparaison avec une population de prédicteurs, appelés aussi "*experts*" dans la littérature¹⁵. Nous cherchons alors quelle est la perte ou *regret* maximal de la méthode d'apprentissage par rapport au meilleur expert, y compris un apprenant qui disposerait de toutes les données en un coup (hors ligne).

Ces travaux s'affranchissent des hypothèses de données tirées aléatoirement et indépendamment suivant une distribution fixe, seul cadre dans lequel il est possible d'établir des théorèmes de convergence uniforme sur des fonctions de distribution. L'environnement obéit en effet rarement à cette hypothèse. L'apprenant modifie les distributions de données par son action, la tâche d'apprentissage évolue, l'environnement évolue.

14. Un ensemble de test indépendant de la séquence d'apprentissage est aussi utilisé dans des méthodes d'apprentissage actif dans un flux de données, abordées plus loin (Dagan et Engelson, 1995; Liere et Tadepalli, 1997; Ho et Wechsler, 2004).

15. Ce cadre s'appelle aussi apprentissage à partir d'avis d'experts, "using expert advices"

Les objectifs des méthodes d'évaluation présentées diffèrent. Un ensemble de test peut être constitué d'exemples provenant de plusieurs séquences distinctes dans le temps. Il permettra alors d'évaluer une performance moyenne sur ces séquences et les périodes auxquelles elles appartiennent, en supposant une certaine stabilité sur ces périodes dans la distribution des données. Par opposition, évaluer l'hypothèse au fur et à mesure sur les exemples de la séquence utilisée en apprentissage comme dans le cas de l'apprentissage avec nombre d'erreurs ne permet pas de connaître la performance de l'hypothèse courante sur d'autres exemples que ceux vus récemment, depuis la dernière mise à jour de l'hypothèse. Un tel cadre, dans lequel les étiquettes sont disponibles en permanence, n'est de plus tout simplement pas réaliste¹⁶. Les étiquettes proviennent en général d'un expert dont la disponibilité est limitée. Même lorsque des techniques de suivi des performances sont prévues, l'hypothèse sera utilisée en prédiction la majeure partie du temps sans pouvoir contrôler la qualité de la prédiction. Il est alors intéressant d'avoir évalué sa qualité sur des données "variées".

Dans notre application, nous nous sommes placés dans un cadre en ligne. Nous devons cependant traiter une base de données finie. S'il serait intéressant d'employer des méthodes de suivi des performances des hypothèses, nous nous sommes limités dans ce travail à un apprentissage sur une séquence finie de données, et nous évaluons la performance des hypothèses construites sur des ensembles de test indépendants, que nous choisissons avec des caractéristiques variées dans la base de données. Ceci nous permet de nous assurer que les hypothèses sont performantes sur différentes séquences, et nous donne une confiance raisonnable pour utiliser les hypothèses en prédiction sur des données nouvelles.

5.3 Apprentissage incrémental par sélection de données dans un flux

Nous présentons une solution originale pour notre problématique. Les travaux présentés ici ont fait l'objet de communications (Saunier *et al.*, 2004a; Saunier *et al.*, 2004c).

5.3.1 Quels objectifs ?

Nous devons commencer par préciser nos critères de performance pour le système appris, par rapport à notre problème, l'estimation de la sévérité des interactions entre mobiles. Nous voulons évidemment construire un système qui fasse le moins d'erreurs possible. Il n'y a pas vraiment de classe à privilégier, car toute erreur sur une classe c , que ce soit un exemple de la classe c mis dans une autre classe¹⁷, ou un exemple d'une autre classe, mis dans la classe c ¹⁸, a un impact sur les autres. Dans un problème typiquement

16. Il n'y a pas d'application dans laquelle des méthodes d'apprentissage soient nécessaires et les étiquettes soient disponibles en toute circonstance. Quel serait alors le besoin de méthodes d'apprentissage s'il existe un moyen permanent d'obtenir automatiquement les étiquettes ?

17. Soit un "faux négatif", un exemple x tel que $u = c$ et $h(x) \neq c$.

18. Soit un "faux positif", un exemple x tel que $u \neq c$ et $h(x) = c$.

à trois classes, il n'est pas possible de négliger une seule classe, car toute erreur sur la classe "négligée" a un impact sur les autres classes. Il n'est pas non plus pertinent d'inventer une fonction de perte personnelle ajustée pour que nos méthodes aient de bons résultats. Nous préférons donc utiliser la fonction de perte 0-1 introduite précédemment, pour laquelle le risque réel devient la probabilité de mauvaise classification. Nous nous intéressons aux performances détaillées par classe, telles que définies par les mesures de rappel et de précision.

Nous traitons les données dans leur cadre séquentiel naturel pour les raisons évoquées plus haut, en particulier la possibilité de mise à jour des hypothèses. Nous avons donc travaillé sur des algorithmes d'apprentissage incrémentaux. Nous évaluons la performance des hypothèses construites sur des ensembles de test indépendants constitués de séquences différentes, sous des conditions de trafic et des stratégies différentes. Ceci nous permet de nous assurer dans une certaine mesure que les hypothèses peuvent être utilisées sur plusieurs séquences, sous différentes conditions de trafic et indépendamment des stratégies. Nous pouvons ensuite faire des comparaisons entre stratégies toutes choses égales par ailleurs.

Lors des débuts des travaux sur ce problème d'apprentissage, nous avons étiqueté des séquences de données, et les avons utilisées dans un cadre hors ligne, sans utiliser leur ordre. Nous avons utilisé des algorithmes classiques comme des classifieurs bayésiens naïfs, des réseaux de neurones avec rétro-propagation du gradient. Ces premiers essais ont montré des performances qui ne nous satisfaisaient pas, en particulier pour les classes de sévérité extrême, dont les effectifs sont les plus faibles. Nous avons en outre constaté que les classes se chevauchent : des exemples peuvent être très proches et pourtant étiquetés dans des classes distinctes sans aucun doute de la part de l'expert. Dans le cadre que nous avons décrit, notre objectif est d'améliorer les performances des hypothèses produites, globalement et pour chaque classe. Nous comparons dans la suite les performances des algorithmes classiques et celles de nos propositions.

Puisque les classes se chevauchent, il est important de favoriser l'information concernant les zones frontières entre les classes, afin que l'hypothèse construite fasse le moins d'erreurs possibles sur les exemples proches de ces frontières. Pour cela, nous proposons de sélectionner un sous-ensemble des données d'apprentissage disponibles. Une hypothèse apprise sur un ensemble dans lequel sont sur-représentés les exemples situés dans les zones frontières doit permettre de mieux préciser les frontières entre classes qu'une hypothèse apprise sur l'ensemble des données. Une des conséquences est de déformer la distribution naturelle des données, qui n'est pas connue dans le cadre en ligne, puisque les données arrivent au fur et à mesure du temps. Dans la plupart des méthodes d'apprentissage étudiées jusqu'à maintenant, l'apprenant reçoit passivement des données de l'environnement. Une méthode qui sélectionne les données d'apprentissage implique que l'apprenant soit *actif*, i.e. ait un certain contrôle sur les données d'apprentissage. C'est la

définition de l'*apprentissage actif* donnée par D. Cohn en 1990 (Cohn *et al.*, 1994)¹⁹ (cf figure 5.4). Dans ce cadre ont été développées de nombreuses méthodes de sélection des données.

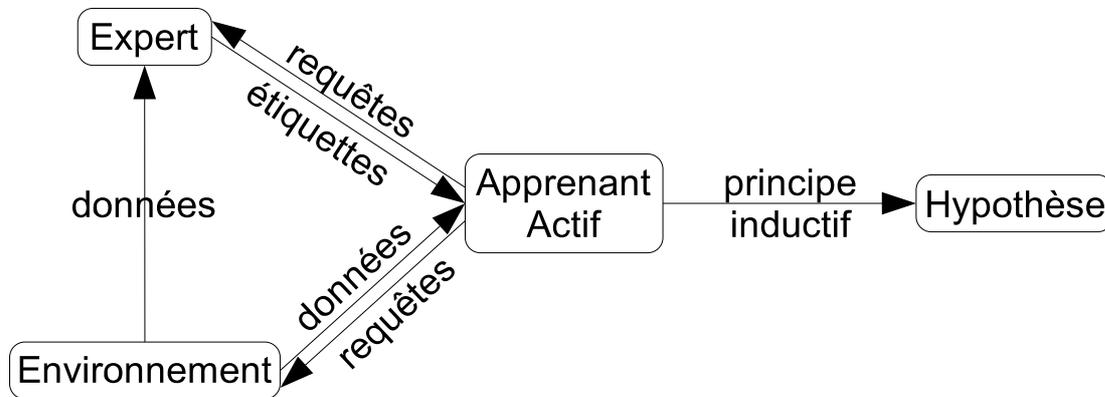


FIGURE 5.4 – Par opposition au schéma de la figure 5.1, décrivant un apprenant *passif*, l'apprenant est *actif* et peut faire des requêtes sur les données.

5.3.2 Introduction à l'apprentissage actif

Dans le cadre de l'apprentissage actif, l'apprenant peut envoyer des requêtes à l'environnement et l'expert (Tong, 2001; Cornuéjols *et al.*, 2002; Baram *et al.*, 2004).

- Le cadre le plus courant est appelé *cadre sélectif* ("selective setting" ou "selective sampling", l'apprentissage dans ce cadre est aussi appelé "query learning"), dans lequel l'apprenant peut faire des *requêtes d'appartenance* ("membership queries"), i.e. demander l'étiquette d'un exemple à l'expert. Des travaux théoriques s'interrogent sur le nombre minimum de requêtes nécessaire à l'apprenant pour produire la meilleure hypothèse. Les requêtes d'appartenance concernent exclusivement des exemples non-étiquetés dans la plupart des travaux. Il a aussi été envisagé des requêtes sur des exemples artificiels construits par l'apprenant (sens strict parfois donné aux requêtes d'appartenance), ce qui peut poser des problèmes car ces exemples peuvent n'avoir aucun sens, i.e. ne pas être étiquetables²⁰ (Lindenbaum *et al.*, 1999). (Tong, 2001) parle de cadre *interventionniste* ("interventional setting") dans lequel l'apprenant peut demander à faire des expériences.
- Dans le protocole de requête d'équivalence, l'apprenant peut proposer une hypothèse h et l'expert soit l'informe que l'hypothèse est logiquement équivalente à la fonction cible, soit lui fournit un contre-exemple infirmant l'hypothèse.
- Dans le protocole de requête statistique, l'apprenant ne peut avoir accès strictement aux exemples étiquetés, mais peut poser des questions sur les statistiques des exemples étiquetés.

19. "By active learning, we mean any form of learning in which the learning program has some control over the inputs it trains on."(Cohn *et al.*, 1994), cité dans (Fürnkranz, 1998)

20. Par exemple, générer des images dans une tâche de reconnaissance de caractères manuscrits.

S'il est acquis que certains protocoles permettent de réduire la taille de l'échantillon d'apprentissage nécessaire²¹, aucun résultat ne permet d'affirmer que l'apprentissage actif soit plus puissant que l'apprentissage passif en terme de fonctions apprenables (Cornuéjols *et al.*, 2002).

Pour notre travail, nous sommes intéressés par les méthodes de sélection des données comme les requêtes d'appartenance sur des données non-étiquetées, soit le cadre sélectif. Ce type de méthodes est adapté lorsqu'il y a abondance d'exemples, et que l'obtention de leurs étiquettes a un coût. Au lieu de recevoir passivement les données aléatoirement tirées selon la distribution des données, l'apprenant peut sélectionner les données qui améliorent au mieux les performances des hypothèses construites, et ainsi limiter le recours à l'expert pour l'étiquetage des données. Une analogie est celle de l'étudiant actif qui pose des questions au professeur, écoute les réponses et pose de nouvelles questions selon les réponses, tandis que l'étudiant passif écoute juste le cours.

La plupart des algorithmes d'apprentissage actif travaillent dans le cadre d'un *réservoir de données* ("pool-based") (Yan *et al.*, 2003; Baram *et al.*, 2004; Tong, 2001; Roy et McCallum, 2001; Iyengar *et al.*, 2000; Abe et Mamitsuka, 1998; Freund *et al.*, 1997; Seung *et al.*, 1992; Lewis et Catlett, 1994; Lewis et Gale, 1994; Atlas *et al.*, 1990; Cohn *et al.*, 1994; Schohn et Cohn, 2000; Lindenbaum *et al.*, 1999), dans lequel un ensemble fixe d'exemples non-étiquetés et complètement accessibles est présenté à l'apprenant. A chaque étape, l'apprenant choisit un ou plusieurs exemples dans le réservoir de données pour qu'ils soient étiquetés. L'expert les étiquette et l'apprenant construit une hypothèse à partir de tous les exemples étiquetés jusque là. Nous travaillons dans un cadre séquentiel, ce qui nous conduit à considérer la variante dans le cas d'un *flux continu de données* non-étiquetées ("stream-based"), étudiée dans (Dagan et Engelson, 1995; Liere et Tadepalli, 1997; Freund *et al.*, 1997; Cesa-Bianchi *et al.*, 2003; Cesa-Bianchi *et al.*, 2004; Ho et Wechsler, 2004). A l'arrivée de chaque exemple, l'apprenant doit choisir s'il demande à l'expert de l'étiqueter. La figure 5.5 illustre les deux cadres de l'apprentissage actif.

Quel que soit le cadre, il est très profitable que l'algorithme d'apprentissage soit incrémental puisqu'à chaque ajout de nouveaux exemples étiquetés, l'hypothèse doit être réapprise ou mise à jour. Dans tous les cas, l'apprentissage actif nécessite plus de ressources qu'un apprentissage passif, et peut se voir comme une utilisation accrue des ressources computationnelles pour limiter le recours à l'expert.

Il faut noter que l'apprentissage actif n'est pas la seule façon d'utiliser des données non-étiquetées abondantes. Le sujet est traité dans *l'apprentissage avec des données étiquetées et non-étiquetées* ("learning with labeled-unlabeled examples"), appelé aussi *apprentissage semi-supervisé* ("semi-supervised learning") (Seeger, 2000; Ghani et Rosenberg, 2003). Cette présentation de l'apprentissage actif fournit le cadre et des solutions pour des méthodes de sélection des données.

21. Dans un cadre non-bruité, (Freund *et al.*, 1997) a prouvé que l'algorithme de requête par comité ("query-by-committee") fournit une accélération exponentielle de la vitesse d'apprentissage par rapport à une sélection aléatoire.

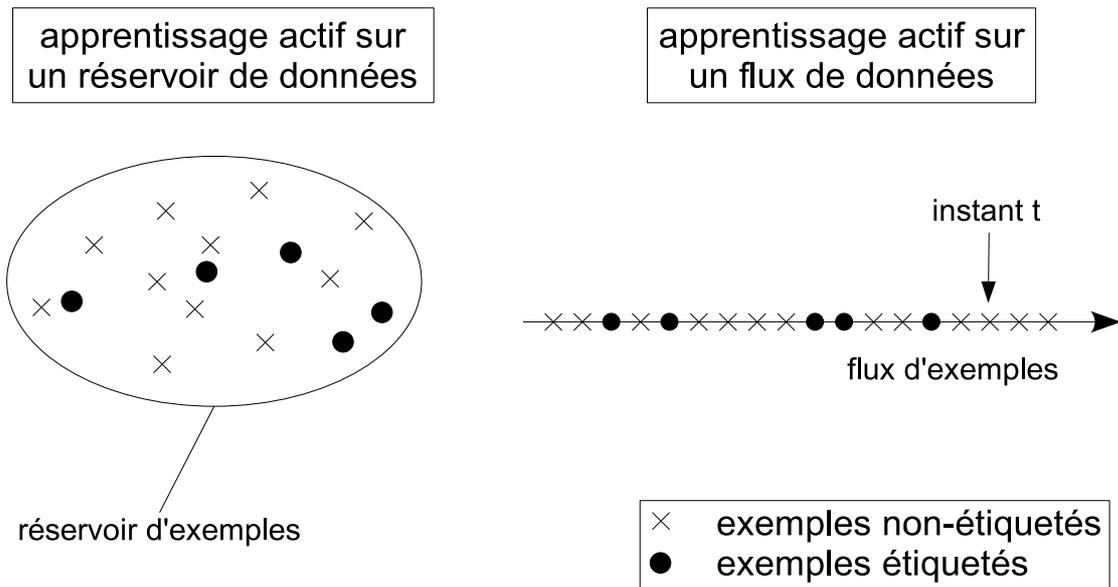


FIGURE 5.5 – A l’instant t , l’apprenant peut sélectionner *n’importe quel* exemple dans un réservoir de données, alors que l’apprenant est limité à l’exemple *courant* dans un flux de données.

5.3.3 Sélection de données dans un flux

Le principe générique des algorithmes incrémentaux de sélection des données dans un flux est décrit dans l’algorithme 1. Les éléments importants sont les critères de sélection des données et d’arrêt. Pour traiter un flux de données, il est nécessaire que l’algorithme soit incrémental, et donc que l’algorithme A générant l’hypothèse de base le soit aussi, ainsi que le critère de sélection des données.

Les critères existants de sélection des données

Une première possibilité consiste à sélectionner les données avant leur étiquetage. Quels sont les critères utilisés dans les méthodes d’apprentissage actif ? Le but est de choisir des exemples qui, une fois étiquetés et pris en compte par l’apprenant, améliorent les performances des hypothèses apprises. Un grand nombre de méthodes s’appuie sur le concept d’*espace des versions*. L’espace des versions pour un ensemble de données étiquetées S et une famille d’hypothèses H est l’ensemble des hypothèses de H cohérentes avec les exemples de S , i.e. de risque empirique nul sur S . Sur ce principe, des méthodes d’apprentissage actif essaient de choisir des exemples qui réduisent au maximum la taille de l’espace des versions.

Il existe nettement moins de travaux empiriques dans le cadre d’un flux de données que dans celui d’un réservoir de données. L’algorithme le plus connu utilisant l’espace des versions est l’algorithme de *requête par comité* ("query-by-committee", QBC) (Seung *et al.*, 1992; Dagan et Engelson, 1995; Liere et Tadepalli, 1997; Freund *et al.*, 1997). Il con-

Algorithme 1 : Algorithme générique de sélection de données dans un flux.

Entrées : Soit A l'algorithme incrémental d'apprentissage de l'hypothèse de base

Soit $x_t \in X$ l'exemple disponible à l'instant t

Soit $y_t \in Y$ la classe (inconnue) de x_t

Soit $U = Y \cup \{\text{étiquettes floues}\}$ l'ensemble des étiquettes que l'expert peut attribuer à x_t

Soient $F = [x_t]$ un flux d'exemples, et E_{init} un ensemble initial d'exemples étiquetés

Soit $h : X \rightarrow Y$ une hypothèse retournée par A

Sorties : Hypothèse finale h_{finale}

début

Appliquer A à E_{init} pour construire h

$t = 0$

répéter

si $CritèreSélection(x_t, h)$ *satisfait* **alors**

 Mise à jour de h avec (x_t, u_t) selon A ($u_t \in U$ est obtenue dans

$CritèreSélection$)

$t = t + 1$

jusqu'à $CritèreArrêt$

fin

siste à tirer aléatoirement un nombre pair d'hypothèses (2 en général) dans un comité d'hypothèses de l'espace des versions, potentiellement infini, et à sélectionner l'exemple courant si ces hypothèses sont en désaccord sur la prédiction de sa classe. L'une des difficultés de cette méthode tient à l'exploration de l'espace des versions. (Dagan et Engelson, 1995) propose de calculer une mesure du désaccord du comité d'hypothèses, basée sur l'entropie du vote du comité, mesure qui une fois normalisée constitue la probabilité que l'exemple soit sélectionné. L'hypothèse utilisée en prédiction est soit une hypothèse tirée de l'espace des versions, ou un vote des hypothèses du comité. Cesa-Bianchi a développé des méthodes particulières liées à des classifieurs à seuil linéaire comme winnow, illustrant ses travaux théoriques cités plus haut dans le cadre d'un flux de données (Cesa-Bianchi *et al.*, 2003; Cesa-Bianchi *et al.*, 2004). (Cesa-Bianchi *et al.*, 2003) utilise un seuil sur un critère lié à chaque exemple, ainsi que (Ho et Wechsler, 2004) avec des SVM incrémentaux pour la transduction.

Il existe nettement plus de méthodes dans le cadre d'un réservoir de données. (McCallum et Nigam, 1998) considère comme un désavantage d'utiliser l'algorithme de requête par comité dans le cadre d'un flux de données en sélectionnant les exemples indépendamment les uns des autres. Il préfère choisir parmi les exemples d'un réservoir de données celui ou ceux qui optimisent le désaccord du comité, mesuré dans cet article par la divergence de Kullback-Leibler. Différentes approches et mesures ont été développées dans les méthodes de requête par comité. (Abe et Mamitsuka, 1998) utilise des méthodes de combinaison d'hypothèses, Bagging et Boosting, pour générer un comité d'hypothèses et quantifier leur désaccord comme leur marge sur l'exemple²². (Melville et

22. Une hypothèse probabiliste h produit pour chaque exemple une distribution de probabilité sur les classes. Les sorties de nombreuses familles d'hypothèses, comme les réseaux de neurones, peuvent être normalisées

Mooney, 2004) mesure le désaccord d'un comité d'hypothèses constitué selon (Melville et Mooney, 2003) de la même façon. Des méthodes par "rééchantillonnage adaptatif" ("adaptive resampling") utilisent aussi plusieurs hypothèses pour tirer des ensembles d'exemples selon une distribution proportionnelle à la variance des prédictions de l'ensemble des hypothèses (Saar-Tsechansky et Provost, 2004) ou au nombre d'erreurs de l'ensemble des hypothèses (Iyengar *et al.*, 2000) (en prenant une hypothèse générée par un autre algorithme comme expert).

Suivant l'approche des algorithmes de requête par comité basée sur une notion d'incertitude des prédictions (le désaccord du comité), (Lewis et Catlett, 1994; Lewis et Gale, 1994) utilise une seule hypothèse probabiliste, et sélectionne les exemples pour lesquels la confiance, i.e. la probabilité de la classe prédite, est la plus faible (proche de 0.5 dans un problème de classification binaire). (McCallum et Nigam, 1998) insiste sur l'importance de sélectionner des exemples dans des zones denses de l'espace des données, pour qu'ils apportent de l'information concernant d'autres exemples, et incorporent pour cela une mesure explicite de densité à l'utilité de chaque exemple. Il faut noter qu'un flux de données entraîne cet effet implicitement. Dans le cas où deux "vues" redondantes, i.e. des ensembles d'attributs décrivant les données, supposées indépendantes existent sur les données, la méthode de "co-training" consiste à apprendre une hypothèse sur chaque vue et à sélectionner les exemples sur lesquels ces hypothèses sont en désaccord (Blum et Mitchell, 1998; Muslea *et al.*, 2000; Ghani, 2002).

(Cohn *et al.*, 1994) propose un algorithme basé sur des réseaux de neurones, explicitant une zone d'incertitude à l'aide du réseau de neurones le plus spécifique et du réseau le plus général, tous les deux cohérents avec les données étiquetées. Un exemple est dans la zone d'incertitude s'il existe deux réseaux cohérents avec les données étiquetées qui soient en désaccord sur sa classe. Sélectionner des exemples situés dans cette zone diminue alors la taille de l'espace des versions. Les algorithmes les plus efficaces selon (Baram *et al.*, 2004) utilisent des SVM et essaient de réduire la taille de l'espace des versions (Schohn et Cohn, 2000; Tong, 2001). Ces méthodes sélectionnent les exemples les plus proches de l'hyperplan du SVM courant et font preuve d'un comportement empirique très satisfaisant.

Cependant, aucune des méthodes citées jusqu'à présent n'optimise directement la métrique selon laquelle l'apprenant sera finalement évalué, l'espérance de l'erreur de l'apprenant sur un futur ensemble de test. Dans le cas précis de modèles d'apprentissage statistiques (Cohn *et al.*, 1995), il est possible de calculer cette valeur exactement. Cela n'est pas possible en général, mais la valeur peut être estimée en utilisant les prédictions de l'hypothèse courante (Roy et McCallum, 2001).

Pour conclure, (Baram *et al.*, 2004) propose un algorithme qui combine un ensemble d'algorithmes d'apprentissage actif, (Tong, 2001), (Roy et McCallum, 2001) et un dernier

et considérées comme une distribution de probabilité. La marge d'un classifieur probabiliste h sur un exemple x est la différence entre la probabilité la plus élevée et la seconde plus élevée. Elle peut être vue comme une mesure de l'incertitude de l'hypothèse dans sa prédiction.

algorithme original dit "furthest-first traversals" sélectionnant les exemples les plus éloignés des exemples déjà vus. La performance de l'algorithme résultant est toujours proche de la meilleure performance des trois algorithmes utilisés, et la dépasse sur certains problèmes.

Quel critère pour sélectionner les données dans notre flux ?

Les solutions qui s'offrent à nous pour sélectionner les données dans un flux avant leur étiquetage sont les suivantes (les notations sont celles de l'algorithme 1) :

- l'algorithme de requête par comité originel (Dagan et Engelson, 1995) (QBC),

CritèreSélection(x_t, h) :

h est alors obtenue par vote d'un comité d'hypothèses.

Tirer aléatoirement 2 hypothèses du comité d'hypothèses, h_1 et h_2 .

Si $h_1(x_t) \neq h_2(x_t)$, sélectionner x_t et demander son étiquette à l'expert.

- nous pouvons adapter les méthodes mesurant une utilité (désaccord d'un comité d'hypothèses, marge ou confiance d'une hypothèse...) associée à chaque exemple dans le cadre d'un réservoir de données selon deux méthodes déjà mises en œuvre dans le cadre d'un flux de données,
 - utiliser un seuil sur cette utilité (Ho et Wechsler, 2004),

CritèreSélection(x_t, h) :

Si *utilité*(x_t) < *seuil*, sélectionner x_t et demander son étiquette à l'expert.

- considérer cette utilité comme une probabilité de choisir l'exemple (Dagan et Engelson, 1995).

CritèreSélection(x_t, h) :

utilité(x_t) est supposée normalisée sur [0, 1].

Tirer une variable aléatoire *rand* selon une loi uniforme sur [0, 1].

Si *rand* < *utilité*(x_t), sélectionner x_t et demander son étiquette à l'expert.

Puisque le but de ces méthodes est de limiter le recours à l'expert en sélectionnant les données à étiqueter, elles traitent les données non-étiquetées. Notre objectif étant d'augmenter les performances des hypothèses, nous avons aussi envisagé des méthodes de sélection des données une fois *étiquetées*. Ne pas utiliser toutes les données étiquetées en apprentissage peut sembler contre-intuitif. Nous montrons cependant que cela peut apporter des gains. Nous nous intéressons en particulier à la technique proposée par R. Quinlan pour l'algorithme d'apprentissage par arbre de décision ID3, et repris plus récemment dans (Fürnkranz, 1998). "Windowing" est une technique de sous-échantillonnage des données, sélectionnant itérativement un sous-ensemble d'apprentissage, la "fenêtre", constitué des données mal-classées par l'hypothèse courante. Les motivations pour utiliser cette technique citées dans (Fürnkranz, 1998) sont les suivantes : limiter les ressources nécessaires en mémoire et calcul, et obtenir des gains de performances, observés sur certains problèmes. Ces gains de performances sur un sous-ensemble des données d'apprentissage ont été observés avec des méthodes d'apprentissage actif par exemple (Schohn et Cohn, 2000). Ce critère de choix des données mal-classées a des liens

avec les techniques de ré-échantillonnage adaptatif, comme le "Boosting" et les travaux présentés dans (Iyengar *et al.*, 2000), qui se concentrent sur les exemples les plus difficiles à apprendre. Nous y revenons dans la suite.

Nous avons testé les différents critères de sélection des données dans un flux. Nous préférons éviter les méthodes faisant intervenir un paramètre supplémentaire comme un seuil sur l'utilité des exemples, car l'ajustement de tels seuils présente des problèmes de robustesse. Nous avons constaté expérimentalement que la sélection des exemples Mal-Classés par l'hypothèse courante, appelé critère MC, donne les meilleurs résultats en performance pour notre problème. Par extension, l'algorithme MC désigne l'algorithme de sélection de données dans un flux avec le critère MC.

Nous devons encore préciser l'utilisation des données aux étiquettes floues.

Les étiquettes floues

Comment utiliser les données pour lesquelles l'information de supervision fournie par l'expert est ce que nous avons appelé une étiquette floue ? Une étiquette floue indique une incertitude sur l'appartenance de l'exemple entre deux classes, mais surtout une certitude de non-appartenance pour toutes les autres classes. Il est possible d'utiliser cette information avec la technique dite de code correcteur d'erreur ("error-correcting output coding", ECOC). Cette technique permet de convertir un problème de classification multi-classe traité par co-training (Ghani, 2002), et sert aussi dans les méthodes de combinaison d'hypothèses présentées plus loin (Dietterich, 2002). Elle consiste à convertir un problème de classification à N_C classes en N problèmes de classification binaire, avec $N < N_C$. A chaque classe est associée une chaîne binaire unique de longueur N . N hypothèses sont ensuite apprises pour prédire chaque bit de la chaîne. La classe prédite est celle dont la chaîne est la plus proche de celle produite par les hypothèses en comptant le nombre de bits en accord (distance de Hamming). Le nombre de problèmes de classification binaires déduits est inférieur au nombre de classes initiales et il est possible d'utiliser des méthodes existantes pour construire les codes de chaque classe. Le désavantage principal tient au fait que les problèmes de classification binaire déduits n'ont pas forcément de sens par rapport aux données, par exemple lorsque des classes naturellement "éloignées" se retrouvent "ensemble" dans un problème binaire.

Nous avons fait des essais dans notre cas. En présence de 3 classes ordonnées, il suffit de créer deux problèmes de classification binaires, de chaque classe extrême contre les autres. Ainsi, un exemple à l'étiquette floue pourra être systématiquement utilisé dans un des deux ensembles d'apprentissage. La conversion des étiquettes est montrée dans le tableau 5.1.

Cette idée est très attirante car elle permet de tirer le meilleur parti des informations fournies par l'expert, en particulier les exemples aux étiquettes floues, mais aussi l'ordre des classes, de façon similaire à (Frank et Hall, 2001). Les expériences ont cependant montré que l'utilisation de ces exemples par cette technique n'apportait aucune amélioration significative des performances des hypothèses. Nous pouvons proposer deux explica-

Étiquettes de l'expert	MIN / reste	MAX / reste
MIN	1	0
MIN-MOY	/	0
MOY	0	0
MOY-MAX	0	/
MAX	0	1

TABLE 5.1 – Conversion possible d'un problème de classification avec 3 classes ordonnées (MIN, MOY et MAX) (avec donc deux étiquettes floues, MIN-MOY et MOY-MAX), en deux problèmes de classification binaires, respectivement les classes MIN ou MAX contre les autres classes (1 indique l'appartenance à la classe, 0 la non-appartenance, et / la non-utilisation de l'exemple).

tions à cela. Tout d'abord, il y a tout de même un nombre important d'exemples étiquetés dans les trois classes, même s'il est déséquilibré. En outre, les exemples aux étiquettes floues apportent réellement peu d'information, en particulier pour ce que nous avons identifié comme le plus crucial, les frontières entre les classes, puisque leur position par rapport à cette frontière est inconnue.

En dernier recours, nous avons pensé utiliser ces exemples dans des ensembles de test. Pour la même raison qu'ils n'apportent apparemment pas d'information en apprentissage, leur classe prédite est rarement en désaccord avec leur étiquette. Ils ne permettent alors pas de discriminer les algorithmes d'apprentissage quant à leur performance.

Nous avons donc décidé de ne pas utiliser les exemples aux étiquettes floues en apprentissage pour simplifier la construction des hypothèses. Le critère de sélection des exemples MC complet est écrit formellement de la façon suivante, avec les notations de l'algorithme 1. Nous n'utilisons pas non plus les exemples aux étiquettes floues en test.

CritèreSélectionMC(x_t, h) :

Demander à l'expert d'étiqueter x_t : soit u_t cette étiquette.

Si $u_t \in Y$ (l'étiquette u_t n'est pas floue) et $h(x_t) \neq u_t$, sélectionner x_t .

5.3.4 Critère d'arrêt

Nous nous sommes placés dans un cadre séquentiel, avec apprentissage sur une séquence de données limitée dans le temps par la disponibilité de l'expert pour superviser l'apprentissage. Ceci pose un premier critère d'arrêt indépassable (Lindenbaum *et al.*, 1999). Le rôle d'un tel critère est de stopper l'apprentissage lorsque la qualité des hypothèses construites, en particulier leur performance, est satisfaisante. Cette problématique est très étroitement liée à la question du suivi des performances pour détecter des changements de concepts. La solution classique naturelle consiste à utiliser un ensemble de validation construit comme l'ensemble de test, indépendant de l'ensemble de test. Nous aimerions utiliser tous les exemples disponibles en apprentissage et étudions donc les méthodes alternatives.

La plupart des algorithmes d'apprentissage actif avec réservoir de données choisissent l'une des hypothèses apprises durant le processus d'apprentissage actif. Puisque

leurs performances augmentent avec la taille de l'ensemble d'apprentissage, le critère d'arrêt n'est pas crucial. Les auteurs représentent la croissance des performances en fonction du nombre de données étiquetées, et mettent en avant la réduction du nombre d'exemples nécessaires pour atteindre un niveau de performance donné. Des critères d'arrêt et des méthodes pour estimer la performance d'une hypothèse ne sont pas abordés dans le cadre d'un flux de données, et dans peu de travaux dans le cadre d'un réservoir de données. (Schohn et Cohn, 2000; Baram *et al.*, 2004) mettent en évidence le fait que la performance réelle d'une hypothèse n'est pas disponible. Même des méthodes standards d'évaluation de la performance comme la validation croisée ne permettent pas d'obtenir une estimation fiable de l'erreur réelle d'une hypothèse obtenue par apprentissage actif, car la distribution de l'ensemble d'apprentissage est biaisée par le processus de l'apprentissage actif vers les exemples difficiles à apprendre, et est donc différente de la vraie distribution des données. (Baram *et al.*, 2004) introduit un estimateur empirique, de maximisation de l'entropie de classification qui est expérimentalement suffisamment corrélé avec la performance des hypothèses pour permettre de choisir le meilleur algorithme d'apprentissage actif en ligne. (Schohn et Cohn, 2000) utilise des caractéristiques des SVM, à savoir le nombre d'exemples devenant vecteurs de support, et remarque que les performances de l'hypothèse sont meilleures pour ce critère d'arrêt que lorsque toutes les données disponibles sont étiquetées et utilisées en apprentissage.

La littérature offre donc peu de solutions génériques. Pour notre part, nous privilégions en premier lieu l'amélioration de la qualité des hypothèses construites pour faire le meilleur usage des exemples étiquetés par l'expert. Nous n'utilisons pas de critère d'arrêt à proprement parler : la disponibilité de l'expert détermine le nombre d'exemples étiquetés disponibles et donc l'arrêt d'une séquence d'apprentissage. Une fois une séquence finie, des méthodes de suivi des performances peuvent être nécessaires et imposer une reprise de l'apprentissage. Nous les abordons à la fin de ce chapitre.

Nous aimerions que la performance des hypothèses construites augmente en fonction du nombre d'exemples sélectionnés, et ne se dégrade pas une fois une performance satisfaisante atteinte. Or, nous constatons que l'algorithme d'apprentissage par sélection de données dans un flux avec le critère de sélection des données MC est *instable*. Un algorithme est instable si de "petits" changements dans l'ensemble d'apprentissage conduisent à des hypothèses significativement différentes et à des variations de performance relativement "grands" (Duda et Hart, 2000; Dietterich, 2002). Cette variance est différente de la variance de l'algorithme à ensemble d'apprentissage fixé évoquée dans le compromis biais-variance. Pour réduire l'instabilité de notre algorithme, nous nous sommes intéressés aux méthodes de combinaison d'hypothèses.

5.3.5 Combiner les hypothèses pour améliorer la stabilité des performances

Etat de l'art

Les méthodes consistant à combiner plusieurs hypothèses font partie des avancées transversales les plus intéressantes dans le domaine de l'apprentissage artificiel. Une conférence annuelle leur est consacrée²³. Elles ont connu des succès sur de nombreux problèmes en permettant l'amélioration des performances par rapport à leur hypothèses composantes. Une de leur grande force provient du fait que ces méthodes sont relativement indépendantes de la famille des hypothèses combinées, ce qui permet de choisir les hypothèses les plus adaptées à chaque tâche.

(Dietterich, 2002) présente un bon panorama des *méthodes de combinaison d'hypothèses* ("ensemble methods"). Les hypothèses combinées sont souvent appelées *hypothèses de base* ou composantes, et constituent un *ensemble* ou *comité*. Comme nous l'avons vu en introduction de ce chapitre, il y a toujours un compromis biais-variance dans le choix d'un algorithme d'apprentissage. La variance provient d'un espace des hypothèses trop large, entraînant un choix non-optimal par l'algorithme d'apprentissage parmi plusieurs hypothèses de qualité équivalente, par exemple toutes de risque empirique nul. Le biais apparaît lorsque l'espace des hypothèses ne contient pas la fonction-cible. Les méthodes de combinaison d'hypothèses ont des résultats car elles peuvent s'attaquer à ces problèmes. Elles fonctionnent en faisant tourner un algorithme plusieurs fois pour former un *vote*, pondéré ou non, des différentes hypothèses construites. Le vote consiste concrètement à choisir la classe majoritaire parmi les prédictions des hypothèses de l'ensemble ou, si ces dernières sont probabilistes, à moyenniser les distributions de probabilités sur les classes fournies par chaque hypothèse. Si les N_h hypothèses probabilistes de l'ensemble sont notées h_i ($1 \leq i \leq N_h$) et $P_{h_i,y}(x)$ la probabilité qu'un exemple x appartienne à la classe y selon l'hypothèse h_i , le vote est obtenu de la façon suivante,

$$P_{vote,y}(x) = \frac{1}{N_h} \sum_{1 \leq i \leq N_h} P_{h_i,y}(x)$$

Il y a deux approches principales pour combiner des hypothèses. La première approche consiste à construire chaque hypothèse indépendamment des autres de telle façon qu'elles soient raisonnablement précises et diverses, i.e. qu'elles soient en désaccord sur un certains nombre d'exemples. Intuitivement, l'hypothèse résultante sera alors plus précise que ses composantes, car les désaccords s'annuleront. Cette approche s'attaque au problème de la variance. Différentes méthodes permettent d'obtenir des hypothèses diverses :

- Utiliser des ensembles d'apprentissage légèrement différents pour construire chaque hypothèse. Un algorithme instable est un bon candidat pour cette méthode. La méthode de ce type la plus connue est "*Bagging*" ("bootstrap aggregating"), qui consiste à tirer avec remise des sous-ensembles de l'ensemble d'apprentissage (Breiman, 1996) (méthode de tirage appelée bootstrap).

23. International Workshop on Multiple Classifier Systems : <http://www.diee.unica.it/mcs/>.

- Apprendre les hypothèses sur des sous-ensembles différents des attributs décrivant les données.
- Manipuler les étiquettes des données d'apprentissage, par exemple avec la méthode des codes correcteurs d'erreur décrits plus haut ("ECOC").
- Rendre aléatoire l'algorithme d'apprentissage. Construire des réseaux de neurones avec l'algorithme de rétro-propagation du gradient à partir d'une initialisation aléatoire des poids est un exemple. Les algorithmes d'apprentissage par arbre de décision ont aussi été largement utilisés de cette façon (Dietterich, 2000; Geurts, 2003).

La seconde approche consiste à construire les hypothèses d'une façon couplée de sorte que le vote pondéré des hypothèses soit bien adapté aux données. Cette approche s'attaque au problème du biais. Un vote pondéré d'hypothèses peut augmenter le pouvoir de représentation des hypothèses. Par exemple, la combinaison d'hypothèses linéaires peut être non-linéaire. L'exemple le plus connu est la famille des méthodes de "Boosting"²⁴ (Schapire, 1990), dont l'algorithme le plus connu est "AdaBoost" ("adaptive boosting") dans sa version décrite dans (Freund, 1995), appelée aussi "AdaBoost.M1" (cf algorithme 2). Dans le cadre de l'analyse dans le pire des cas, un résultat fort a été montré : tout algorithme d'apprentissage produisant des hypothèses faisant mieux qu'une procédure de choix aléatoire (apprenant dit faible) peut être "boosté" jusqu'à atteindre une erreur aussi faible que voulue et ce avec une probabilité aussi grande que désirée et en temps polynomial (apprenant dit fort) (Schapire, 1990; Freund, 1995).

Le principe d'AdaBoost est d'associer un poids à chaque exemple, puis de solliciter l'apprenant faible sur ces exemples et ces poids pour obtenir une hypothèse qui classe correctement les exemples de poids forts²⁵ ; ensuite, les poids des exemples sont modifiés multiplicativement en fonction de cette hypothèse (les poids des bien classés sont diminués et ceux des mal classés augmentés) et le processus itéré. A chaque hypothèse est associé un poids lié à son erreur sur l'ensemble d'apprentissage, qui est utilisé ensuite dans le vote final des hypothèses. AdaBoost a permis de tester les idées du Boosting sur des données réelles. Les performances d'AdaBoost sont excellentes sur la grande majorité des ensembles de données (Dietterich, 2000). Les raisons de ce succès sont partiellement comprises. Une explication tient à la maximisation des marges d'AdaBoost sur les exemples d'apprentissage²⁶. Il est ainsi souvent rapporté que le risque réel peut continuer à diminuer, même lorsque le risque empirique n'évolue plus (il est parfois simplement nul) (Schapire *et al.*, 1997; Dietterich, 2002). Cependant, des méthodes maximisant explicitement la marge des hypothèses produites donnent de moins bons résultats qu'AdaBoost. Des inconnues demeurent, quant à la définition des apprenants faibles, le choix du nombre d'itérations, la taille des ensembles d'apprentissage (Torre, 2004). AdaBoost montre ses limites dans deux cas : les données bruitées (Bagging est dans ce cas souvent

24. Cette famille de méthodes populaires a même son site internet : <http://www.boosting.org/>.

25. Soit l'hypothèse prend directement en compte les poids par exemple, soit elle est apprise sur un sous-ensemble des données d'apprentissage dont le tirage est pondéré par les poids des exemples

26. Ces remarques ont conduit à chercher un lien entre le boosting et les SVM (Cornuéjols *et al.*, 2002).

Algorithme 2 : Algorithme AdaBoost (cas d'un problème de classification binaire avec $u \in \{+1, -1\}$ (version tirée de (Cornuéjols *et al.*, 2002))).

Entrées : Soit A l'algorithme incrémental d'apprentissage de l'hypothèse de base

Soit $S = \{(x_1, u_1), (x_2, u_2), \dots, (x_m, u_m)\}$ l'ensemble d'apprentissage, avec

$u_i \in \{+1, -1\}$

Soit p une distribution de probabilité sur S , initialisée à $1/m$ ($p(x_i)$ est le poids de x_i)

Soit $h_k : X \rightarrow Y$ une hypothèse retournée par A , et α_k son poids dans la combinaison finale

Soit N_h le nombre d'étapes de l'algorithme, correspondant au nombre d'hypothèses h_k combinées

Sorties : Hypothèse finale $h_{finale}(x) = \text{signe}(\sum_{k=1}^{N_h} \alpha_k h_k(x))$

début

pour $k = 1 \dots N_h$ **faire**

Tirer un échantillon d'apprentissage S_k de S selon la distribution p

Apprendre une hypothèse h_k sur S_k par l'algorithme A

Soit ϵ_k l'erreur apparente de h_k sur S .

$\epsilon_k = p(h_k(x_i) \neq u_i) = \sum_{i|h_k(x_i) \neq u_i} p(x_i)$

Calculer $\alpha_k = \frac{1}{2} \ln \frac{1-\epsilon_k}{\epsilon_k}$

pour $i = 1 \dots m$ **faire**

Si $h_k(x_i) = u_i$, $p(x_i) = \frac{p(x_i)}{Z_k} e^{-\epsilon_k}$

Si $h_k(x_i) \neq u_i$, $p(x_i) = \frac{p(x_i)}{Z_k} e^{+\epsilon_k}$

(Z_k est une constante de normalisation telle que $\sum_{i=1}^m p(x_i) = 1$);

fin

meilleur qu'AdaBoost) et les ensembles d'apprentissage de petite taille (Dietterich, 2000; Dietterich, 2002).

Récemment, (Melville et Mooney, 2003) mélange les deux approches et crée de façon couplée un ensemble d'hypothèses en cherchant à maximiser leur diversité par l'ajout de données artificielles. (Seewald, 2003) propose la méthode de "stacking" qui permet de décrire dans un même cadre un grand nombre de méthodes de combinaison d'hypothèses, dont Bagging.

Comment combiner des hypothèses produites par sélection de données dans un flux ?

Nous voulons améliorer la stabilité de notre algorithme MC. Nous venons de voir que les méthodes de combinaisons d'hypothèses permettent d'obtenir souvent des hypothèses plus stables et plus performantes. Nous avons donc pensé former un vote de plusieurs hypothèses produites par l'algorithme MC. Quelles hypothèses utiliser ?

Dans un premier temps (Saunier *et al.*, 2004a; Saunier *et al.*, 2004c), nous avons remarqué que de nombreuses hypothèses sont apprises durant le processus d'apprentissage, et peuvent être combinées pour former l'hypothèse finale. Nous avons formé un vote de tout ou partie des hypothèses construites durant le processus d'apprentissage. Nous avons utilisé les dernières hypothèses construites car elles sont apprises avec le plus grand nombre d'exemples. Pour les mêmes raisons de stabilité, l'hypothèse utilisée dans

le critère de sélection est une combinaison par vote des hypothèses précédemment construites. Cette version de l'algorithme incrémental de sélection des données est présentée dans l'algorithme 3. Les paramètres de cet algorithme sont le nombre d'exemples de l'ensemble d'initialisation $n_{init} = |E_{init}|$ ²⁷ et le nombre d'hypothèses combinées par vote N_h .

Algorithme 3 : Algorithme de sélection de données dans un flux, avec le critère MC, et vote des dernières hypothèses formées.

Entrées : Soit $h_j : X \rightarrow Y$ une hypothèse retournée par A , après la sélection de j exemples

Soit N_h le nombre d'hypothèses combinées par vote

Soit $Vote_{i_1, i_2}$ l'hypothèse obtenue par vote des hypothèses de $\{h_j \mid i_1 \leq j \leq i_2\}$

Soient $F = [x_t]$ un flux d'exemples, et E_{init} un ensemble initial d'exemples étiquetés

Sorties : Hypothèse $Vote_{max(0, j-N_h), j}$

début

Appliquer A à E_{init} pour construire h_0

$j = 0$

$t = 0$

répéter

si *CritèreSélectionMC*($x_t, Vote_{max(0, j-N_h), j}$) *satisfait* **alors**

Mise à jour de h_j en h_{j+1} avec (x_t, u_t) selon A ($u_t \in U$ est obtenue dans *CritèreSélectionMC*)

$j = j + 1$

$t = t + 1$

jusqu'à *CritèreArrêt*

fin

Cet algorithme a amélioré les performances, mais restait instable. Une des causes de ce problème provient du fait que les hypothèses combinées diffèrent peu les unes des autres. h_{j+1} étant la mise à jour de h_j avec un exemple, elles ont le même ensemble d'exemples sélectionnés pour l'apprentissage, à un exemple près. La différence entre les hypothèses apprises sur ces ensembles s'amenuise à mesure que le nombre d'exemples vus augmente. Une possibilité pour remédier à cela serait de constituer le vote d'hypothèses "espacées" d'un nombre d'exemples sélectionnés proportionnel au nombre d'exemples déjà utilisés, de sorte que les hypothèses combinées soient plus diverses.

La clef de la qualité du vote d'un ensemble d'hypothèses est effectivement leur diversité. Nous choisissons alors l'approche d'un comité d'hypothèses, construites indépendamment en parallèle. Or, si l'algorithme de base A est déterministe, i.e. son comportement peut être complètement prédit à partir de ses entrées, l'algorithme MC l'est aussi. Pour une initialisation et une séquence données, l'algorithme sélectionnera systématiquement les mêmes exemples. L'hypothèse $h_{E_{init}, h, F}$ produite par l'algorithme MC est définie par l'ensemble d'initialisation $E_{init, h}$ et la séquence des exemples F . Par définition, nous ne maîtrisons pas l'ordre de présentation des exemples dans un cadre en ligne. Nous

27. $|E|$ désigne le cardinal de l'ensemble E .

devons donc perturber son initialisation pour obtenir des hypothèses diverses. Une solution alternative consiste à utiliser un algorithme A aléatoire, ou à rendre aléatoire un algorithme déterministe (Dietterich, 2000).

Nous avons choisi de travailler avec des algorithmes incrémentaux déterministes pour servir d'algorithme de base A , car nous avons obtenu en particulier de bons résultats avec l'algorithme des classifieurs bayésiens naïfs. Nous fournissons à l'algorithme MC des ensembles d'initialisation différents, à partir d'un ensemble global d'initialisation E_{init} pour tout le comité. Si l'algorithme A n'est pas sensible à l'ordre de présentation des exemples (c'est le cas de l'algorithme des classifieurs bayésiens naïfs), l'initialisation de l'algorithme MC ne l'est pas non plus et, il ne suffit alors pas de changer l'ordre des exemples des ensembles d'initialisation. Une solution consiste à tirer aléatoirement un sous-ensemble d'initialisation plus petit $E_{init,h}$ pour chaque hypothèse. Pour utiliser tous les exemples, une fois un algorithme MC initialisé sur un tirage de $E_{init,h}$ dans E_{init} , les exemples restant de $E_{init} \setminus E_{init,h}$ (complémentaire de $E_{init,h}$ dans E_{init}) sont présentés pour être sélectionnés, comme s'ils faisaient partie du flux F . Ceci est notre algorithme principal, intitulé *Vote MC* (cf algorithme 4). Nous notons l'hypothèse produite $Vote_{E_{init},F,n_{init,h},N_h}$, formée par le vote du comité de N_h hypothèses de $\{h_{E_{init,h},F} \mid E_{init,h} \subset E_{init} \text{ et } |E_{init,h}| = n_{init,h}\}$ produites par l'algorithme MC sur $E_{init,h}$ et F . A ensemble d'initialisation E_{init} et séquence F fixées, les paramètres de *Vote MC* sont $n_{init,h}$ et N_h . Si nous étudions plus particulièrement cet algorithme avec le critère de sélection des données MC, il n'en reste pas moins générique et peut être utilisé avec d'autres critères de sélection comme ceux présentés plus haut. Nous l'appelons *Vote*, et selon le critère de sélection utilisé, *Vote CritèreSélection*.

Dans la description de l'algorithme 4, nous ne répétons pas le détail de l'algorithme MC pour la fin de l'initialisation de chaque hypothèse h_k sur $E_{init} \setminus E_{init,k}$. Nous ne l'incluons pas non plus dans le flux de données F car l'initialisation n'est pas incrémentale, chaque hypothèse est initialisée indépendamment des autres. Lors du traitement du flux, les données peuvent aussi être vues comme produites indépendamment les unes des autres, ce qui peut être le cas hors ligne. Pour autant, notre algorithme 4 est incrémental et met à jour les hypothèses h_k à chaque arrivée d'un nouvel exemple x_t .

L'algorithme MC peut se voir comme une extension de la technique de Windowing pour traiter un flux de données. L'algorithme *Vote MC* suit les principes du Boosting, à savoir accentuer le poids des exemples difficiles, mal-classés, dans la distribution des données d'apprentissage. *Vote MC* comporte cependant nettement moins de calculs qu'AdaBoost, l'algorithme de Boosting le plus courant, tel que décrit dans l'algorithme 2, et requiert donc des ressources computationnelles plus faibles. En outre, AdaBoost n'est pas incrémental. Une version incrémentale avec perte est décrite dans (Oza et Russell, 2001). Il ne peut en être autrement puisqu'AdaBoost utilise pour calculer les poids de chaque hypothèse son erreur sur tout l'ensemble d'apprentissage. Les performances de la version incrémentale d'AdaBoost sont équivalentes ou légèrement inférieures à celles de la version non-incrémentale. Nous proposons aussi une version non-incrémentale de

Algorithme 4 : Algorithme Vote MC, de sélection des données mal-classées dans un flux, avec combinaison d'hypothèses initialisées sur des ensembles différents.

Entrées : Soit $h_k : X \rightarrow Y$ une hypothèse retournée par A

Soit N_h le nombre d'hypothèses combinées par vote

Soit $Vote_{N_h}$ l'hypothèse obtenue par vote des hypothèses de $\{h_k \mid 1 \leq k \leq N_h\}$

Soit $E_{init,k}$ l'ensemble d'exemples utilisés pour initialiser chaque h_k

($|E_{init,k}| = n_{init,h}$)

Soient $F = [x_t]$ un flux d'exemples, et E_{init} un ensemble initial d'exemples étiquetés

Sorties : Hypothèse $Vote_{N_h}$

début

Initialisation

Tirer N_h ensembles d'initialisation $E_{init,k} \subset E_{init}$ constitués de $n_{init,h}$ exemples

pour $k = 1 \dots N_h$ **faire**

 Appliquer A à $E_{init,k}$ pour construire h_k

 Traiter le reste des exemples de E_{init} ($E_{init} \setminus E_{init,k}$) comme un flux pour h_k , par l'algorithme MC

Traitement du flux F

$t = 0$

répéter

 Demander à l'expert d'étiqueter x_t : soit u_t cette étiquette

pour $k = 1 \dots N_h$ **faire**

si $u_t \in Y$ et $h(x_t) \neq u_t$ **alors**

 Mise à jour de h_k avec (x_t, u_t) selon A

$t = t + 1$

jusqu'à *Critère Arrêt*

fin

Vote MC, consistant à combiner N_h hypothèses apprises selon l'algorithme MC sur des ensembles dont l'ordre est tiré aléatoirement. Nous appelons cet algorithme *Vote AleaMC*. L'avantage de cet algorithme est de n'avoir que le nombre d'hypothèses combinées N_h comme paramètre, et les bonnes performances que nous présentons dans la suite.

5.4 Etudes expérimentales et validation

Pour montrer l'intérêt de notre démarche et son adéquation à nos objectifs, nous évaluons les algorithmes proposés sur différents problèmes, d'une part des problèmes classiques ("benchmarks"), d'autre part notre problème d'évaluation des indicateurs de sévérité. Les problèmes classiques nous permettent d'établir que nos solutions, bien que construites pour répondre à un problème spécifique, donnent aussi des résultats intéressants sur d'autres problèmes.

Nous avons déjà précisé dans la partie précédente que nous utilisons comme algorithme de base (" A ") dans nos algorithmes un classifieur bayésien naïf ("Naive Bayes", NB). Les résultats de cette partie ont été obtenus de cette façon. Nous avons présenté autant que possible nos algorithmes, MC et Vote MC, de façon générique. La seule con-

trainte est l'incrémentalité de l'algorithme de base. Nous avons choisi un classifieur bayésien naïf car ses performances en apprentissage sur notre problème sont bonnes (par rapport à d'autres algorithmes classiques testés comme les réseaux de neurones), il est incrémental strict, il ne dépend pas de l'ordre de présentation des exemples, il est rapide et n'a pas de paramètres à ajuster. Sa rapidité est particulièrement importante pour nos algorithmes qui mettent à jour les hypothèses de base très souvent²⁸. Les SVM ont de meilleures performances, mais nécessitent nettement plus de temps de calcul. Des classifieurs bayésiens naïfs ont montré de très bonnes performances sur un grand nombre de problèmes (Domingos et Pazzani, 1997), et sont couramment utilisés dans des méthodes de combinaison d'hypothèses comme AdaBoost (Oza et Russell, 2001; Seewald, 2003).

L'algorithme des classifieurs bayésiens naïfs est un des algorithmes mettant en œuvre le principe inductif de décision bayésienne visant à minimiser l'espérance du risque (Webb *et al.*, 2005). Dans le cadre de la fonction de perte 0-1, minimiser l'espérance de risque associé à une hypothèse h revient à choisir la classe y maximisant $P(y|x)$ pour chaque exemple x , soit $\operatorname{argmax}_y P(y|x)$. Nous devons calculer une estimation de la probabilité conditionnelle $\hat{P}(y|x)$ pour obtenir notre règle de classification bayésienne. La définition d'une probabilité conditionnelle donne, appliquée deux fois, la formule de Bayes.

$$P(y|x) = \frac{P(x, y)}{P(x)} = \frac{P(x|y)P(y)}{P(x)}$$

On en déduit $\operatorname{argmax}_y P(y|x) = \operatorname{argmax}_y P(x, y) = \operatorname{argmax}_y P(x|y)P(y)$. En supposant que l'ensemble d'apprentissage est assez représentatif de la distribution croisée $P(x, y)$ des données, la fréquence d'apparition d'une donnée (x, y) dans l'ensemble sera une approximation raisonnable de sa probabilité. Cependant, si le nombre d'attributs d est important, $P(x, y)$ sera très faible, et la fréquence de (x, y) dans l'ensemble d'apprentissage risque d'être nulle. De même, il est probable que x ne soit pas dans l'ensemble d'apprentissage, et qu'il ne soit donc pas possible d'estimer $P(x|y)$. C'est ici qu'intervient l'hypothèse *naïve* d'indépendance des attributs, qui permet d'écrire

$$P(x|y) = \prod_{i=1}^{i=d} P(x_i|y)$$

Un classifieur bayésien naïf classe donc un exemple x avec la classe

$$\operatorname{argmax}_y \left(\hat{P}(y) \prod_{i=1}^{i=d} \hat{P}(x_i|y) \right)$$

où $\hat{P}(y)$ et $\hat{P}(x_i|y)$ sont des estimations des probabilités respectives calculées à partir des fréquences de leurs arguments respectifs dans l'ensemble d'apprentissage, avec lissage de Laplace pour éviter les termes nuls (Webb *et al.*, 2005). Lors de l'apprentissage, il suffit de compiler un tableau du nombre d'exemples par classes et couple attribut-classe. Un nouvel exemple est ainsi facilement pris en compte en mettant à jour ces deux tableaux.

²⁸. Sa rapidité et son incrémentalité en font un algorithme de choix pour les algorithmes d'apprentissage actif, même dans le cadre d'un réservoir de données.

Pour nos implémentations, nous avons utilisé la boîte à outils Weka pour ses nombreuses qualités (cf annexe B) (Witten et Frank, 2000). Pour montrer l'intérêt de nos algorithmes, nous les comparons à d'autres algorithmes existants. Il y a trois types d'algorithmes :

- des algorithmes incrémentaux de sélection d'exemples dans un flux :
 - l'algorithme de sélection d'exemples mal-classés, *MC*,
 - l'algorithme de vote basé sur *MC*, *Vote MC*,
 - l'algorithme de requête par comité de (Dagan et Engelson, 1995), noté *QBC* (cf page 99),
 - l'algorithme de sélection d'exemples avec le critère basé sur la confiance et un seuil, noté *CSeuil* (cf page 99),
 - l'algorithme de sélection d'exemples avec le critère basé sur la confiance et un tirage aléatoire selon cette confiance, noté *CProba* (cf page 99),
 - l'algorithme de Vote basé sur *CSeuil*, noté *Vote CSeuil*,
 - l'algorithme de Vote basé sur *CProba*, noté *Vote CProba*.
- des algorithmes incrémentaux qui utilisent tous les exemples :
 - l'algorithme des classifieurs bayésiens naïfs (implémentation Weka), noté *NB*,
 - l'algorithme de *Bagging*, que nous avons utilisé dans la version incrémentale sans perte de (Oza et Russell, 2001; Lee et Clyde, 2004).
- des algorithmes non-incrémentaux :
 - l'algorithme de vote avec tirage aléatoire de l'ordre des exemples pour chaque hypothèse apprise selon *MC*, *Vote AleaMC*,
 - l'algorithme de Boosting *AdaBoost* (cf algorithme 2) (implémentation Weka),
 - l'algorithme des machines à support de vecteur, *SVM* (implémentation Weka).

L'algorithme des SVM nous sert de référence car c'est une des techniques les plus performantes actuellement sur un grand nombre de problèmes dans le cadre hors ligne. Les versions utilisées de l'algorithme des SVM et d'AdaBoost sont celles disponibles dans Weka et sont non-incrémentales. Des versions incrémentales avec perte existent, et montrent des performances légèrement inférieures à la version non-incrémentale ((Ralaivola et d'Alché Buc, 2001) pour les SVM et (Oza et Russell, 2001) pour AdaBoost). Les versions utilisées nous permettront d'avoir une bonne idée des performances de ces méthodes, incrémentales ou non.

Hormis SVM²⁹, qui n'en a pas besoin, tous ces algorithmes utilisent comme hypothèse de base un classifieur bayésien naïf. Parmi ces algorithmes, les suivants emploient des méthodes de combinaison d'hypothèses : tous les Votes, *QBC*, *Bagging*, *AdaBoost*. Hormis *AdaBoost*, ils construisent tous leurs hypothèses composantes indépendamment les unes des autres, et les combinent par vote. Le nombre d'hypothèses combinées est le même pour tous ces algorithmes, N_h . Tous les algorithmes de sélection d'exemples, et les Votes

29. Les paramètres utilisés de l'algorithme des SVM sont ceux de Weka par défaut, hormis un noyau polynomial d'exposant 2 (paramètre E dans Weka). Nous avons fait des essais avec cet algorithme et ce paramètre améliore sensiblement les performances sur nos données.

basés dessus, font aussi intervenir un nombre d'exemples d'initialisation par hypothèse $n_{init,h}$. Enfin, nous fixons le seuil de CSeuil à 0.95, valeur qui semble intuitivement une valeur de confiance pertinente, sans étude approfondie. Ces paramètres, dont l'algorithme de base A , sont les mêmes pour tous les algorithmes qui les font intervenir, afin de rendre les résultats comparables.

Pour nous mettre dans le cadre réaliste d'un flux de données, les ensembles de données d'initialisation des algorithmes doivent être relativement petits par rapport au flux de données (fini dans notre cas). Sinon, nous ne serions plus dans un cadre en ligne, comme dans le cas "limite" de Vote AleaMC. Tous les algorithmes de Vote, même Vote AleaMC, peuvent être mis à jour sur de nouveaux exemples. Dans ce cas, Vote AleaMC perdrait peu à peu son caractère propre pour se rapprocher de Vote MC.

5.4.1 Problèmes classiques

Nous évaluons nos algorithmes et les comparons aux algorithmes présentés plus haut sur des ensembles de données classiques utilisés dans d'autres publications d'apprentissage artificiel ("benchmarks"). Les caractéristiques des ensembles de données sont présentées dans le tableau 5.2. Les problèmes proviennent tous de la base de données de l'Université de Californie, Irvine (UCI)³⁰ (Blake et Merz, 1998). Certains sont directement disponibles au format utilisé par Weka sur le site de Weka³¹ et un site personnel³². Nous avons converti les autres à partir de fichiers au format C4.5³³.

Problème	Nombre d'exemples	Nombre d'attributs	Nombre de classes
mushroom	8124	23	2
soybean	683	36	19
vote	435	17	2
tic-tac-toe	958	10	2
iris disc	150	5	3
car	1728	7	4
cmc disc	1473	10	3
connect-4	67557	43	3
derma disc	366	35	6
promoters	106	58	2
audiology	226	70	24

TABLE 5.2 – Caractéristiques des 11 problèmes classiques traités, avec leur nombre d'exemples, d'attributs et de classes (cmc veut dire "contraceptive method choice" et derma "dermatology"). Tous leurs attributs sont nominaux.

Les données de ces problèmes n'ont malheureusement pas de caractère séquentiel intrinsèque. Dans ce cas, les algorithmes incrémentaux les traitent en une seule passe,

30. ftp.ics.uci.edu/pub/machine-learning-databases

31. <http://www.cs.waikato.ac.nz/ml/weka/index.html>

32. <http://www.hakank.org>

33. <http://www.grappa.univ-lille3.fr/~torre/guide.php?id=datasets>

selon un ordre aléatoire déterminé par la méthode d'évaluation des algorithmes. Les attributs décrivant les données de tous ces problèmes sont tous nominaux, après discrétisation si nécessaire, pour être comparables à nos données de trafic et être traités directement par l'algorithme des classifieurs bayésiens naïfs. En particulier, l'algorithme des classifieurs bayésiens n'est plus incrémental sans perte si la discrétisation des attributs numériques n'est pas effectuée au préalable³⁴. Dermatology ne contient originellement qu'un attribut numérique, cmc deux attributs numériques, et iris est un problème classique dont tous les attributs sont numériques. Nous avons converti systématiquement ces attributs numériques en attributs nominaux pouvant prendre au maximum 10 valeurs. Le nombre de classes est très variable. Ces problèmes représentent un éventail assez large, avec ou sans valeurs manquantes, plus ou moins "faciles", avec plus ou moins de classes à prédire, de tailles variées.

Nous évaluons la performance des algorithmes sur ces problèmes en répétant 10 fois une validation croisée en 10 ensembles. Pour que les comparaisons soient justes, les partitions en ensembles sont identiques pour tous les algorithmes.

Etude de la sensibilité de Vote MC à ses paramètres

Pour commencer, nous avons étudié la sensibilité de Vote MC à ses paramètres, à savoir le nombre d'exemples d'initialisation de chaque hypothèse $n_{init,h}$ et le nombre d'hypothèses combinées N_h . Nous avons utilisé pour cela 2 des 11 problèmes classiques, "vote" et "tic-tac-toe". "vote" consiste à prédire le parti d'hommes politiques américains à partir de leurs votes. Les exemples de "tic-tac-toe" sont des configurations de fin du jeu du même nom, et il s'agit de prédire le gagnant. tic-tac-toe contient plus de deux fois plus d'exemples que vote. Ce sont deux problèmes de classification binaire, dont tous les attributs sont originellement nominaux, sur lesquels les performances des algorithmes sont bonnes, mais peuvent être améliorées.

Nous évaluons tout d'abord l'impact de la taille de l'ensemble d'initialisation, n_{init} . Nous représentons pour cela le taux de bonne classification en fonction du nombre d'exemples d'initialisation par hypothèse, $n_{init,h}$, cela pour différentes valeurs de n_{init} (10, 20 et 30), respectivement dans les figures 5.6, 5.7 et 5.8. Dans tous les cas, $n_{init,h}$ varie de 1 à n_{init} , valeur pour laquelle les hypothèses formées sont toutes identiques et le vote est donc inutile³⁵. Les courbes pour différentes valeurs du nombre d'hypothèses N_h combinées sont tracées.

L'amplitude des variations de performances ne sont pas les mêmes pour les deux problèmes. Elles sont très réduites pour vote. En dehors de N_h , l'écart-type du taux de bonne classification n'évolue pas significativement en fonction des paramètres. Nous remarquons un comportement différent selon les problèmes. Tandis que les courbes pour

34. La question des traitements des données dans un apprentissage en ligne a été abordée précédemment. Nous discrétisons a priori les attributs numériques pour nous affranchir de ce problème que nous ne traitons pas.

35. Les courbes pour différentes valeurs de N_h atteignent un même point en $n_{init,h} = n_{init}$ car les partitions de validation croisée sont identiques en tout point de l'espace des paramètres.

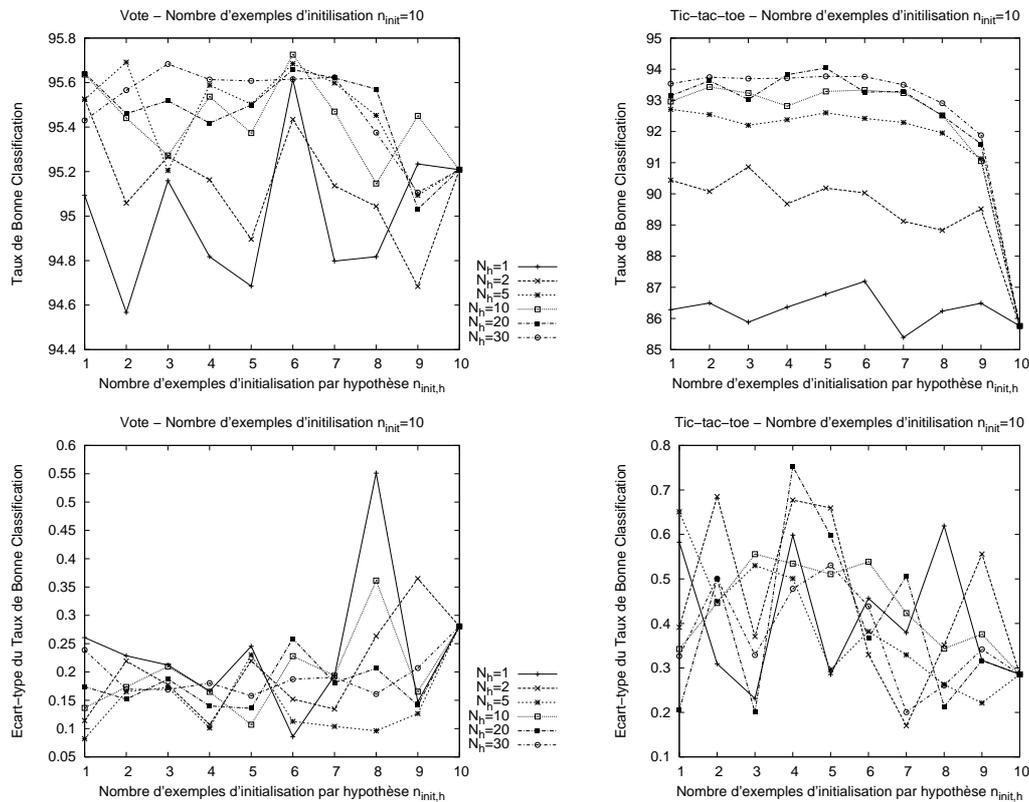


FIGURE 5.6 – Taux de bonne classification (première ligne) et son écart-type (seconde ligne, pour la lisibilité), en fonction du nombre d'exemples d'initialisation par hypothèse $n_{init,h}$, pour un nombre global d'exemples d'initialisation $n_{init} = 10$, pour les problèmes vote (colonne de gauche) et tic-tac-toe (colonne de droite). Les courbes pour différentes valeurs du nombre d'hypothèses combinées N_h sont représentées.

tic-tac-toe ont des formes très proches quel que soit n_{init} , elles se modifient sensiblement pour vote. Plus n_{init} augmente, plus elles montrent un déclin important et prononcé pour des valeurs de $n_{init,h}$ proches de n_{init} . Il est logique que les performances baissent pour $n_{init,h} = n_{init}$, puisqu'il n'y a alors plus de diversité entre les hypothèses formant le vote. En dehors de cette situation à la marge, il apparaît que pour un ensemble de taille importante comme tic-tac-toe, n_{init} pour les valeurs testées n'a pas d'influence sur les performances. Pour un ensemble plus petit comme vote, les courbes semblent tirées d'une même courbe de la performance en fonction de $n_{init,h}$, "indépendamment" de n_{init} . Autrement dit, les courbes pour les valeurs de $n_{init} < 30$ pourraient être des restrictions des courbes pour $n_{init} = 30$. Sur cette courbe commune, plus $n_{init,h}$ augmente, plus les performances diminuent. D'après ces courbes pour l'ensemble vote, nous choisissons donc de prendre la valeur de n_{init} la plus faible testée, 10, car nous voulons conserver le maximum d'exemples pour "simuler" un flux de données. Nous choisissons ensuite $n_{init,h} = 6$, semblant assurer une bonne diversité des hypothèses. Ces paramètres sont

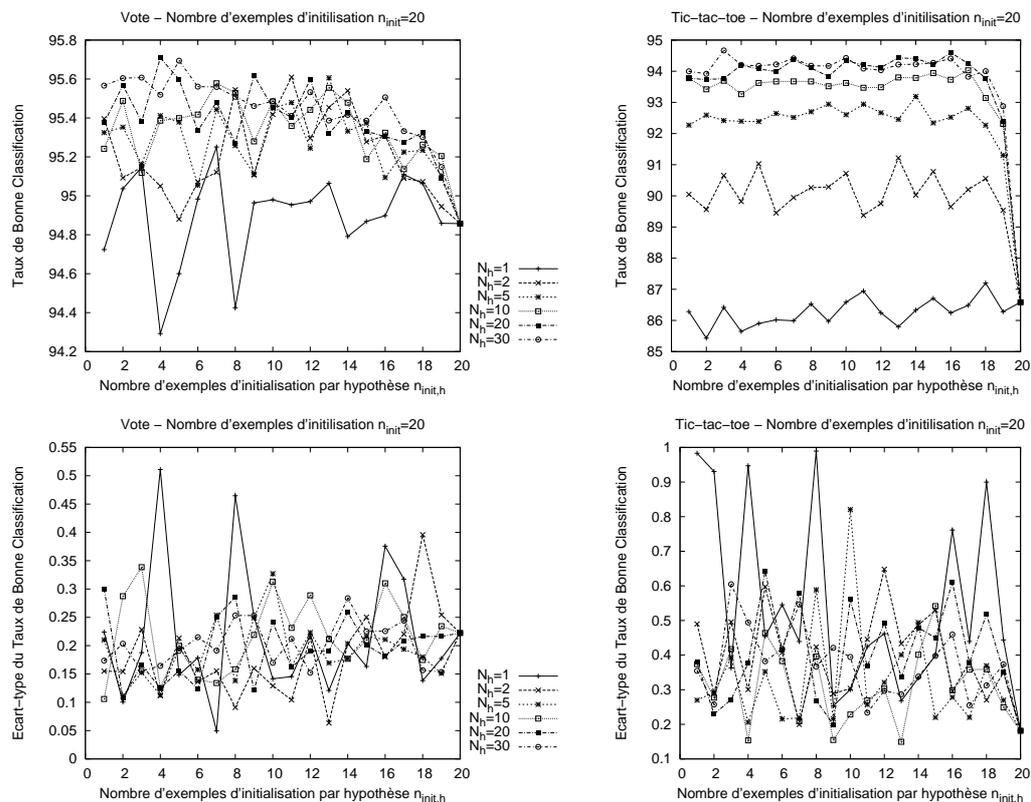


FIGURE 5.7 – Taux de bonne classification (première ligne) et son écart-type (seconde ligne, pour la lisibilité), en fonction du nombre d'exemples d'initialisation par hypothèse $n_{init,h}$, pour un nombre global d'exemples d'initialisation $n_{init} = 20$, pour les problèmes vote (colonne de gauche) et tic-tac-toe (colonne de droite). Les courbes pour différentes valeurs du nombre d'hypothèses combinées N_h sont représentées.

bons pour le problème de tic-tac-toe, mais clairement pas optimaux. Ils semblent être un bon compromis pour les deux ensembles.

Pour $n_{init,h} = 6$, nous avons étudié le comportement des performances en fonction de N_h (cf figure 5.9). Moins clairement pour vote que pour tic-tac-toe, le taux de bonne classification augmente quand N_h augmente. Son écart-type reste de façon un peu surprenante stable. La dépendance à n_{init} pour $n_{init,h} = 6$ est marginale, ce qui confirme notre choix de $n_{init} = 10$. Pour un compromis entre les deux problèmes, et les coûts de calcul, linéaire selon N_h ³⁶, nous choisissons la valeur de $N_h = 10$.

Comparaison des performances des algorithmes

Nous présentons les résultats en deux tableaux pour des raisons de place et d'analyse, en reprenant dans tous les cas nos deux algorithmes MC et Vote MC, dans la table 5.3 pour le taux de bonne classification avec son écart-type, dans les tableaux 5.4 pour le nombre

36. Cela est constaté de façon empirique sur les temps de calcul présentés dans la partie B.1.

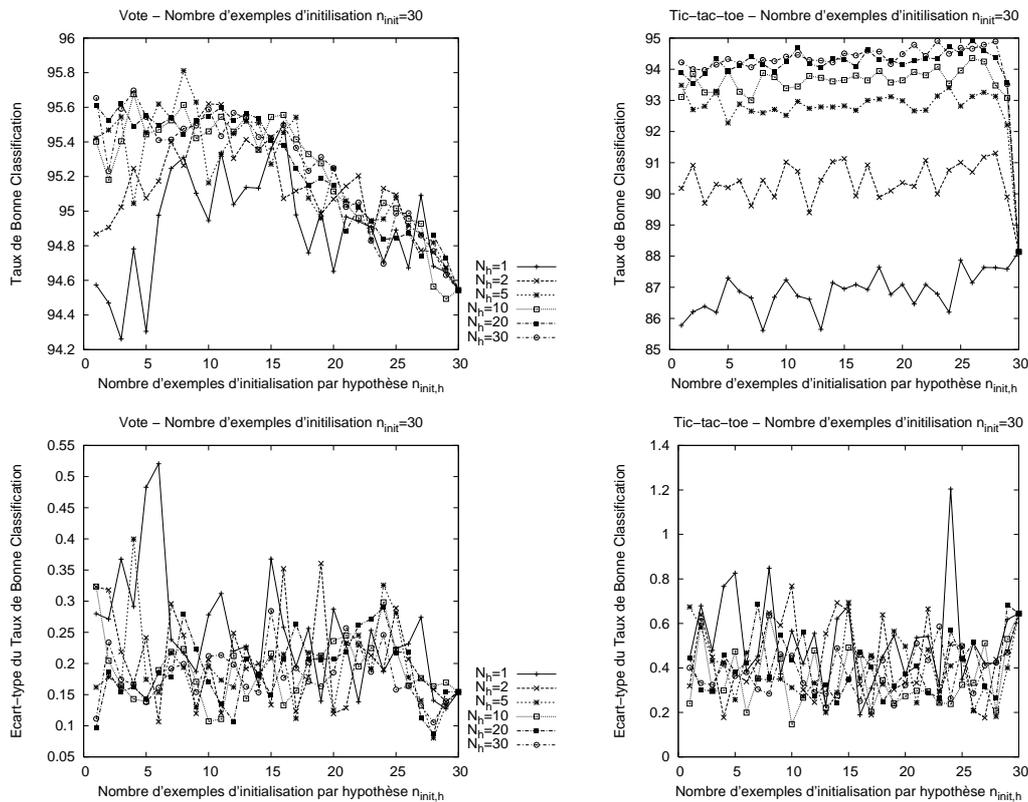


FIGURE 5.8 – Taux de bonne classification (première ligne) et son écart-type (seconde ligne, pour la lisibilité), en fonction du nombre d'exemples d'initialisation par hypothèse $n_{init,h}$, pour un nombre global d'exemples d'initialisation $n_{init} = 30$, pour les problèmes vote (colonne de gauche) et tic-tac-toe (colonne de droite). Les courbes pour différentes valeurs du nombre d'hypothèses combinées N_h sont représentées.

d'exemples sélectionnés et les tableaux B.1 pour les temps de calcul. Tous ces résultats sont des moyennes et écart-types issus de 10 validations croisées en 10 ensembles.

Nous voulons en effet comparer nos algorithmes aux autres algorithmes de sélection de données dans un flux, qui eux sélectionnent les données avant étiquetage (premier tableau) et à d'autres méthodes, pas forcément incrémentales, connues pour leur performances et faisant intervenir pour la plupart des combinaisons d'hypothèses (second tableau).

Tout d'abord, nous pouvons remarquer que sur l'ensemble des problèmes, MC et surtout Vote MC ont les meilleures performances parmi les algorithmes de sélection d'exemples. Ils sont dépassés sur certains problèmes, mais ne sont jamais loin du meilleur dans ces cas, alors que tous les autres algorithmes de sélection d'exemples montrent des faiblesses importantes sur au moins deux problèmes, tic-tac-toe et car, sur lesquels Vote MC se distingue particulièrement. Nous pouvons noter les performances intéressantes de CSeuil et Vote CSeuil, dont le paramètre de seuil n'a pas été ajusté. Il est intéressant de noter que le vote améliore les performances dans tous les cas, rarement de manière

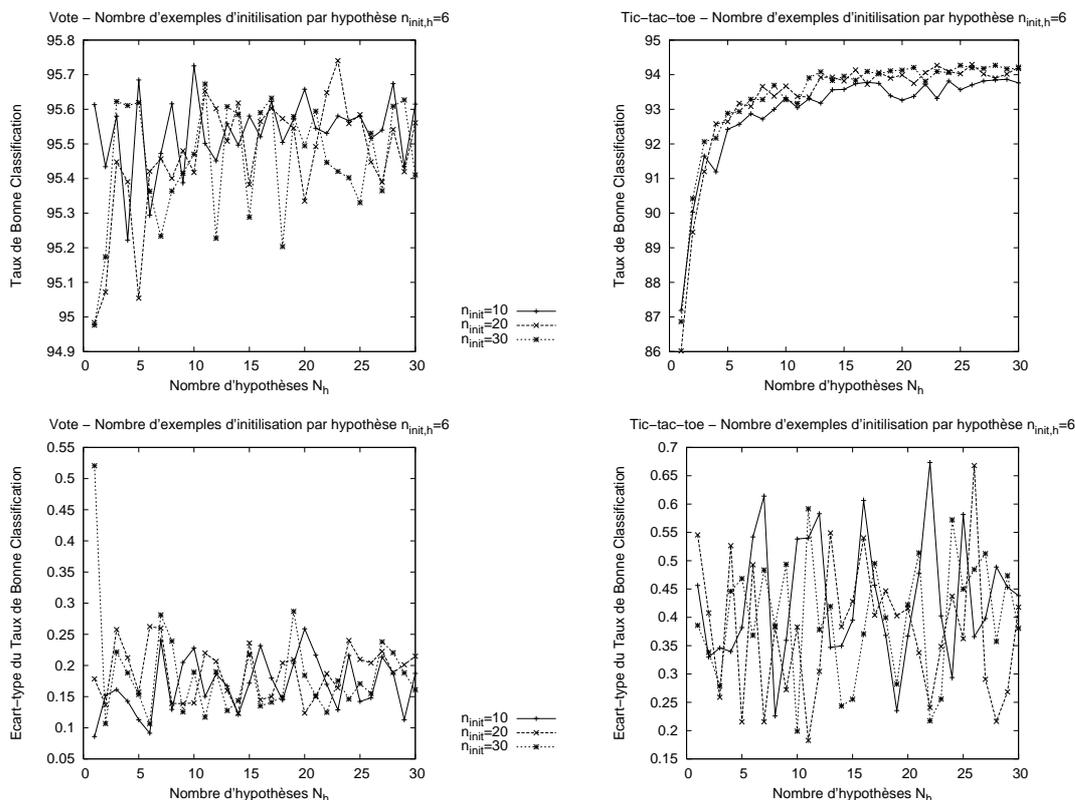


FIGURE 5.9 – Taux de bonne classification (première ligne) et son écart-type (seconde ligne, pour la lisibilité), en fonction du nombre d'hypothèses combinées N_h , pour les problèmes vote (colonne de gauche) et tic-tac-toe (colonne de droite). Les courbes pour différentes valeurs du nombre global d'exemples d'initialisation sont représentées.

significative pour C_{Seuil} et C_{Proba} , sur la majorité des problèmes pour MC. Le meilleur des algorithmes de sélection d'exemples non-étiquetés est QBC, qui montre cependant les mêmes points faibles que les autres algorithmes.

Nous devons ensuite faire quelques remarques sur NB et nos algorithmes, MC, Vote MC et Vote AleaMC. Le bilan de l'amélioration des hypothèses construites par l'algorithme de base, NB, est très mitigé. MC améliore les performances nettement sur 4 problèmes (mushroom, vote, tic-tac-toe et car), est neutre sur 2 problèmes (iris et audiology), et les dégrade sur 5 problèmes (soybean, cmc, connect-4, dermatology et promoters). Pour nuancer ces remarques, il faut noter que même AdaBoost a des difficultés sur ces 5 problèmes : il est neutre ou dégrade lui aussi les performances de NB sur ces problèmes. C'est la même chose pour Bagging qui améliore dans un seul cas les performances de NB, et les dégrade dans deux. Il faut aussi noter que les méthodes de sélection d'exemples se comportent très mal par rapport à NB. Pour être juste, il faut rappeler que ce n'est pas leur rôle d'améliorer les performances de leur hypothèse de base, même si QBC y arrive pour mushroom et vote. Si les performances de NB ne sont pas systématiquement améliorées par MC, elles le sont un peu plus par Vote MC et dans la plupart des cas par Vote AleaMC.

Problème	Vote MC	MC	QBC	CSeuil	CProba	Vote CSeuil	Vote CProba
mushroom	100 ± 0	100 ± 0	99.0 ± 0.1	99.3 ± 0.2	99.4 ± 0.0	100 ± 0	99.5 ± 0.0
soybean	<i>91.6 ± 0.3</i>	<i>90.8 ± 0.2</i>	88.3 ± 0.3	92.6 ± 0.3	85.4 ± 0.3	92.7 ± 0.3	86.8 ± 0.3
vote	95.8 ± 0.3	<i>94.6 ± 0.2</i>	93.7 ± 0.2	95.5 ± 0.2	93.7 ± 0.2	95.6 ± 0.2	94.0 ± 0.2
tic-tac-toe	93.4 ± 0.3	<i>87.1 ± 0.2</i>	71.7 ± 0.4	70.1 ± 0.1	71.4 ± 0.4	70.1 ± 0.1	71.4 ± 0.3
iris disc	<i>94.2 ± 0.3</i>	<i>93.6 ± 0.5</i>	94.5 ± 0.3	93.6 ± 0.2	94.5 ± 0.2	93.5 ± 0.2	94.3 ± 0.2
car	90.7 ± 0.2	<i>89.9 ± 0.1</i>	85.7 ± 0.1	83.2 ± 0.2	84.7 ± 0.2	83.2 ± 0.1	85.0 ± 0.2
cmc disc	<i>51.7 ± 0.2</i>	<i>51.6 ± 0.2</i>	51.7 ± 0.4	52.5 ± 0.2	52.0 ± 0.1	52.5 ± 0.2	51.8 ± 0.1
connect-4	<i>70.6 ± 0.1</i>	<i>70.3 ± 0.1</i>	72.8 ± 0.1	69.6 ± 0.6	71.7 ± 0.3	68.8 ± 0.2	70.3 ± 0.3
derma disc	<i>95.2 ± 0.2</i>	<i>94.6 ± 0.3</i>	95.7 ± 0.3	97.0 ± 0.2	91.9 ± 1.4	97.5 ± 0.2	94.1 ± 0.4
promoters	<i>88.1 ± 1.6</i>	<i>84.8 ± 1.1</i>	82.3 ± 0.8	86.1 ± 0.7	75.8 ± 1.3	89.4 ± 1.1	81.8 ± 0.5
audiology	72.5 ± 0.6	<i>72.2 ± 0.4</i>	61.2 ± 1.0	59.6 ± 2.8	41.9 ± 2.2	65.4 ± 2.4	42.1 ± 1.0

Problème	Vote MC	MC	Bagging	NB	Vote AleaMC	AdaBoost	SVM
mushroom	100 ± 0	100 ± 0	95.7 ± 0.0	95.8 ± 0.0	100 ± 0	100 ± 0	/
soybean	<i>91.6 ± 0.3</i>	<i>90.8 ± 0.2</i>	92.6 ± 0.1	92.9 ± 0.1	92.8 ± 0.1	92.5 ± 0.4	/
vote	<i>95.8 ± 0.3</i>	<i>94.6 ± 0.2</i>	90.2 ± 0.1	90.1 ± 0.0	95.9 ± 0.1	95.6 ± 0.1	94.6 ± 0.1
tic-tac-toe	<i>93.4 ± 0.3</i>	<i>87.1 ± 0.2</i>	70.3 ± 0.1	69.6 ± 0.1	97.9 ± 0.1	80.8 ± 1.0	/
iris disc	<i>94.2 ± 0.3</i>	<i>93.6 ± 0.5</i>	94.3 ± 0.1	94.5 ± 0.1	<i>94.3 ± 0.2</i>	94.4 ± 0.1	94.2 ± 0.2
car	<i>90.7 ± 0.2</i>	<i>89.9 ± 0.1</i>	85.4 ± 0.2	85.8 ± 0.2	92.5 ± 0.1	90.5 ± 0.3	/
cmc disc	<i>51.7 ± 0.2</i>	<i>51.6 ± 0.2</i>	52.1 ± 0.2	52.4 ± 0.1	54.4 ± 0.2	52.4 ± 0.1	/
connect-4	<i>70.6 ± 0.1</i>	<i>70.3 ± 0.1</i>	72.1 ± 0.0	72.1 ± 0.0	73.1 ± 0.0	72.1 ± 0.0	/
derma disc	<i>95.2 ± 0.2</i>	<i>94.6 ± 0.3</i>	97.9 ± 0.1	97.5 ± 0.1	<i>96.9 ± 0.1</i>	97.0 ± 0.1	96.2 ± 0.1
promoters	<i>88.1 ± 1.6</i>	<i>84.8 ± 1.1</i>	88.9 ± 1.0	92.4 ± 0.7	<i>91.5 ± 0.2</i>	90.3 ± 0.7	93.8 ± 0.9
audiology	<i>72.5 ± 0.6</i>	<i>72.2 ± 0.4</i>	71.3 ± 0.2	72.6 ± 0.2	<i>75.8 ± 0.5</i>	80.2 ± 0.3	81.6 ± 0.3

TABLE 5.3 – Moyenne et écart-type du taux de bonne classification sur 10 validations croisées en 10 ensembles, sur les 11 problèmes classiques, pour les algorithmes MC et Vote MC comparés aux algorithmes de sélection de données (à gauche), et les algorithmes basés sur MC comparés aux algorithmes sans sélection d'exemples, incrémentaux et non-incrémentaux (à droite). Les performances de SVM ne sont pas toujours disponibles en raison du coût computationnel de SVM. Le meilleur taux de bonne classification est mis en gras sur chaque ligne, et les performances de nos algorithmes mis en italiques.

Problème	Vote MC	MC	QBC	CSeuil	CProba	Vote CSeuil	Vote CProba
mushroom	45	45	167	403	157	411	161
soybean	114	114	149	220	90	221	88
vote	31	31	31	93	23	93	23
tic-tac-toe	216	216	197	841	220	841	224
iris disc	14	14	15	33	18	33	18
car	230	230	292	939	399	939	399
cmc disc	670	669	402	1286	521	1286	518
connect-4	18363	18361	9936	35980	14969	36817	14673
derma disc	42	42	65	84	33	84	33
promoters	26	27	32	37	14	37	14
audiology	88	88	85	97	27	102	27
Problème	Vote MC	MC	Bagging	NB	Vote AleaMC	AdaBoost	SVM
mushroom	45	45	7312	7312	45	7312	/
soybean	114	114	615	615	113	615	/
vote	31	31	392	392	31	392	392
tic-tac-toe	216	216	862	862	215	862	/
iris disc	14	14	135	135	14	135	135
car	230	230	1555	1555	231	1555	/
cmc disc	670	669	1326	1326	668	1326	/
connect-4	18363	18361	60801	60801	18355	60801	/
derma disc	42	42	329	329	42	329	329
promoters	26	27	95	95	26	95	95
audiology	88	88	203	203	88	203	203

TABLE 5.4 – Moyenne du nombre d'exemples sélectionnés sur 10 validations croisées en 10 ensembles, sur les 11 problèmes classiques, pour tous les algorithmes. Les algorithmes qui ne sélectionnent pas d'exemples sont naturellement notés avec le nombre d'exemples disponibles, soit 9/10 de l'ensemble des données des problèmes. Les performances de SVM ne sont pas toujours disponibles en raison du coût computationnel de SVM.

Vote MC améliore les performances de MC dans tous les cas, pas toujours de façon significative. Vote MC se compare bien à AdaBoost et SVM (dans les cas où nous disposons de ses performances). Il faut remarquer les très bonnes performances de Vote AleaMC, qui ne montre des faiblesses que sur les 3 derniers problèmes, dermatology, promoters et audiology, sur lesquels, NB, AdaBoost ou SVM ont les meilleures performances. Vote AleaMC est très proche, sauf sur audiology.

Il faut noter que l'effet des votes mis en jeu dans une partie des algorithmes est faible sur les écart-types des performances sur la plupart des problèmes. C'est contraire à nos attentes pour Vote MC. Cette observation recoupe celle faite lors de l'étude de la sensibilité des algorithmes aux paramètres.

Concernant le nombre d'exemples sélectionnés (cf tableaux 5.4), il faut tout d'abord noter la très grande proximité entre les votes et leur algorithme de sélection de données simple. Cela peut expliquer les améliorations peu significatives des votes pour la plu-

part des problèmes et algorithmes. Il n’y a par ailleurs pas de corrélation claire entre la performance et le nombre d’exemples sélectionnés.

Nous pouvons revenir sur la comparaison entre nos algorithmes et AdaBoost. Si leurs principes sont similaires, Vote MC et Vote AleaMC sont moins complexes en calculs, en particulier parce qu’ils construisent les hypothèses combinées de façon indépendante. Toutes choses égales par ailleurs, nos algorithmes nécessitent nettement moins de ressources computationnelles en apprentissage sur la plupart des problèmes (cf tableaux B.1). Pour une complexité inférieure, Vote AleaMC a des performances équivalentes ou supérieures à AdaBoost, hormis pour un problème. Quant à Vote MC, le bilan en performances pures est plus contrasté, mais il a l’avantage d’être incrémental.

Nos algorithmes ont des performances intéressantes, voire très bonnes pour Vote AleaMC, sur un ensemble de problèmes variés. Il faut bien garder à l’esprit que le but pour lequel ils ont été développés est notre problème d’évaluation en ligne de la sévérité d’interactions dans le trafic.

5.4.2 L’indicateur de vitesse

Intersection	Origine	Nombre d’exemples Initialisation / F / Test	Nombre d’attributs
K	centre	254 / 755 / 311	81
P	extérieur	66 / 410 / 349	97

TABLE 5.5 – Caractéristiques du problème d’évaluation de la sévérité des interactions en fonction du contexte : nombre d’exemples pour l’ensemble d’initialisation potentiel (dans lequel est tiré E_{init}), le flux de données d’apprentissage F , et l’ensemble de test, et nombres d’attributs.

Nous évaluons maintenant nos algorithmes sur le problème pour lequel ils ont été conçus. Pour cela, nous avons utilisé des données provenant de deux contextes (lieu, origine), à savoir (K, centre) et (P, extérieur) (cf plan de la figure 3.2, p. 40). Cela nous permet d’évaluer les performances sur des problèmes aux caractéristiques légèrement différentes (cf tableau 5.5), et de vérifier qu’ils ne sont pas spécifiques à un contexte. Les données, nominales, sont de tailles différentes, ainsi que les ensembles de données étiquetées. Dans les deux cas, l’expert peut distinguer 3 niveaux de sévérité pour l’indicateur de vitesse, i.e. classes floues ordonnées, comme dans l’exemple de la figure 5.3, notées MIN, MOY et MAX. Il dispose donc de deux étiquettes floues supplémentaires en cas d’incertitude entre deux classes, MIN-MOY et MOY-MAX. Nous n’utilisons cependant pas ces exemples en apprentissage ou en test. La classe MOY est très nettement majoritaire dans les données.

Nous avons fait les évaluations présentées dans la suite avec trois ensembles différents dans chaque contexte (cf tableau 5.5). Nous avons étiqueté complètement les flux de données d’apprentissage sur une certaine période, respectivement environ 35 minutes dans le contexte (P, extérieur) et 50 minutes dans le contexte (K, centre). Les ensembles de

test sont chacun composés des données recueillies lors de 4 séquences de 10 minutes, sous des conditions de trafic différentes, 2 en trafic dense et 2 en trafic fluide. Les ensembles d'initialisation proviennent d'autres courtes périodes. A la différence des études précédentes sur les problèmes classiques, notre problème d'apprentissage des indicateurs de sévérité nous place dans un réel cadre en ligne, avec des données naturellement séquentielles. Nous travaillons sur des ensembles finis complètement étiquetés pour nous permettre de moyennner les résultats d'expériences avec différentes initialisations dans les ensembles prévus à cet effet.

Etude de la sensibilité de Vote MC aux paramètres

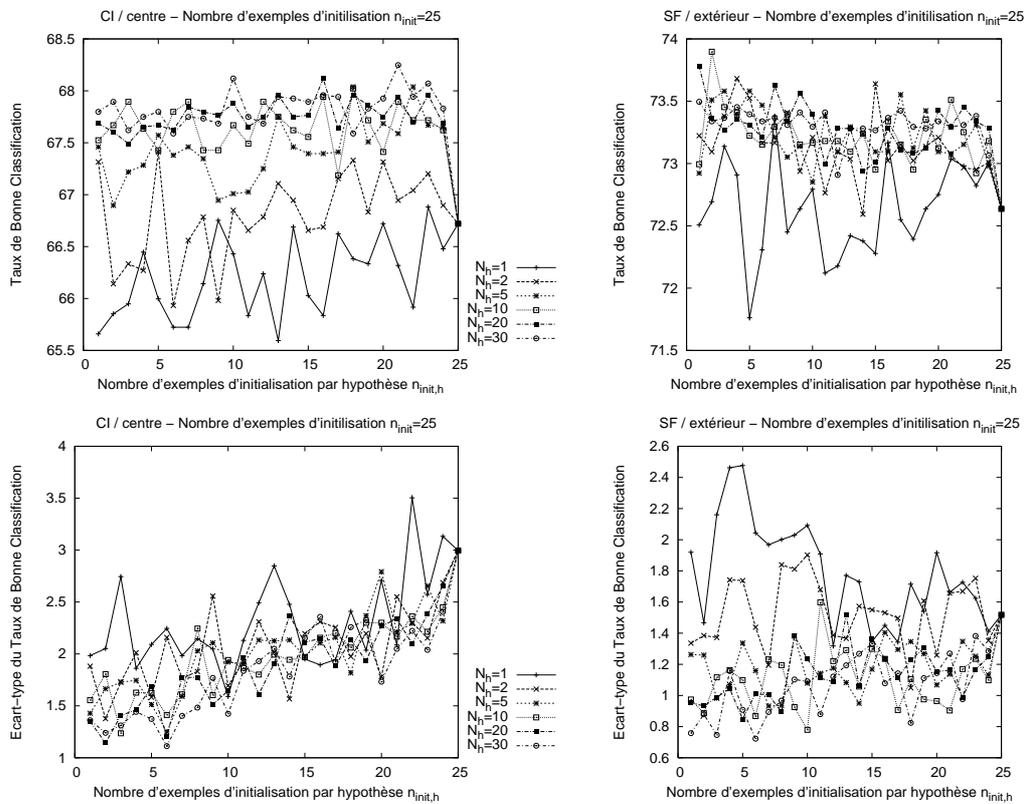


FIGURE 5.10 – Taux de bonne classification (première ligne) et son écart-type (seconde ligne, pour la lisibilité), en fonction du nombre d'exemples d'initialisation par hypothèse $n_{init,h}$, pour un nombre global d'exemples d'initialisation $n_{init} = 25$, pour les contextes (K, centre) (colonne de gauche) et (P, extérieur) (colonne de droite). Les courbes pour différentes valeurs du nombre d'hypothèses combinées N_h sont représentées.

Nous pensons que dans un cadre réaliste, le nombre d'exemples d'initialisation doit être faible. Il doit être suffisant pour permettre une diversité suffisante des hypothèses, mais rester limité. Après le comportement mis en évidence sur les problèmes classiques, nous pensons qu'une valeur de $n_{init} = 25$ est appropriée. Pour cette valeur, nous étudions l'impact de $n_{init,h}$ et N_h sur les performances à l'aide des courbes des figures 5.10 et 5.11.

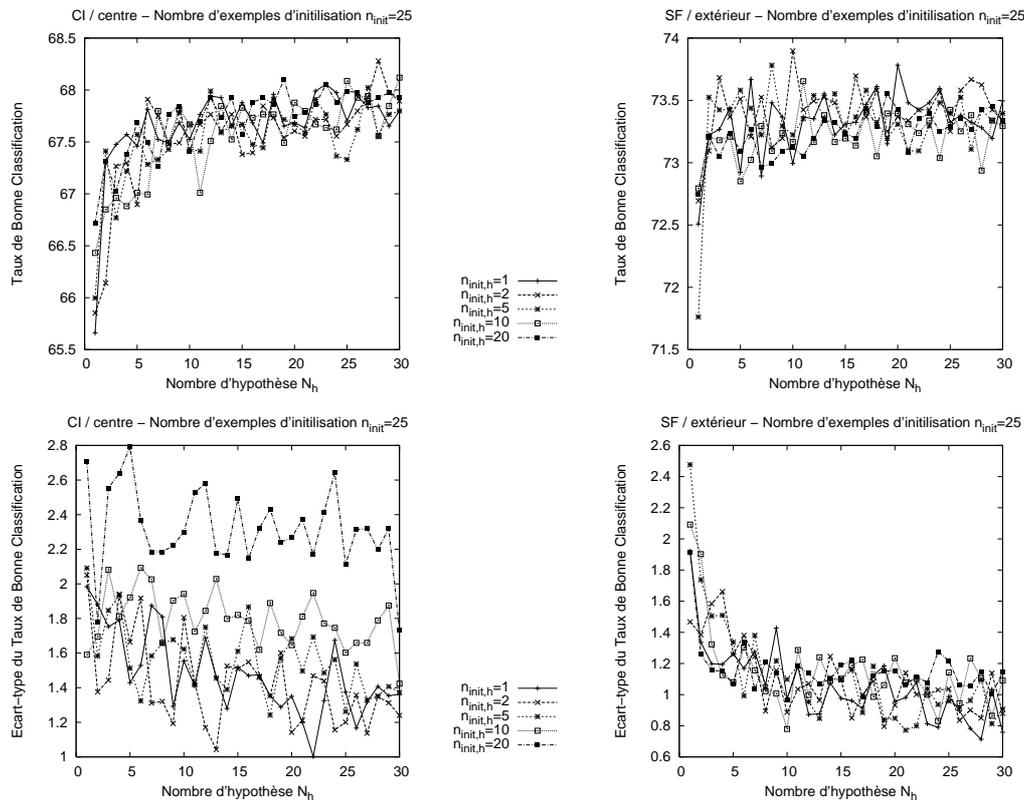


FIGURE 5.11 – Taux de bonne classification (première ligne) et son écart-type (seconde ligne, pour la lisibilité), en fonction du nombre d’hypothèses N_h , pour un nombre global d’exemples d’initialisation $n_{init} = 25$, pour les contextes (K, centre) (colonne de gauche) et (P, extérieur) (colonne de droite). Les courbes pour différentes valeurs du nombre d’exemples d’initialisation $n_{init,h}$ sont représentées.

Tous les résultats de cette partie sont obtenus dans chaque situation sur 20 apprentissages avec initialisation aléatoire.

D’après les premières figures (cf figures 5.10), le taux de bonne classification de Vote MC dépend peu de $n_{init,h}$. Nous notons cependant une légère baisse du taux de bonne classification pour $n_{init,h}$ proche de n_{init} . L’écart-type présente par contre une augmentation régulière en fonction de $n_{init,h}$, qu’il vaut mieux donc choisir plutôt petit (c’est particulièrement visible sur la représentation de l’écart-type du taux de bonne classification en fonction de N_h dans le contexte (K, centre), figure 5.11). Le nombre d’hypothèses combinées N_h a un impact plus important (cf figures 5.11). Les performances de Vote MC augmentent, i.e. le taux de bonne classification augmente et son écart-type diminue, lorsque N_h augmente. Ces performances augmentent peu au-delà de $N_h = 15$. Nous avons déjà observé ce phénomène pour les problèmes classiques. Pour la suite, nous choisissons les valeurs de paramètres suivantes : $n_{init,h} = 6$, $N_h = 18$.

Algorithmme	TBC	R_{MIN}	P_{MIN}	R_{MOY}	P_{MOY}	R_{MAX}	P_{MAX}	Nb Ex
Vote MC	67.8 ± 1.6	72.9 ± 2.1	65.8 ± 2.6	68.4 ± 2.2	78.6 ± 1.5	64.3 ± 3.0	52.3 ± 2.2	235 ± 5
MC	66.2 ± 1.9	72.2 ± 3.6	65.0 ± 4.3	66.9 ± 3.5	77.3 ± 2.4	62.2 ± 5.9	50.6 ± 3.0	235 ± 10
NB	62.5 ± 0.3	73.1 ± 0.6	39.8 ± 1.2	62.2 ± 0.5	75.6 ± 0.4	58.5 ± 1.1	57.4 ± 1.4	780 ± 0
AdaBoost	66.3 ± 1.3	68.1 ± 3.1	56.1 ± 2.4	74.0 ± 2.6	73.7 ± 1.5	49.5 ± 4.5	55.1 ± 2.7	780 ± 0
SVM	75.0 ± 0.8	55.5 ± 3.4	85.1 ± 2.2	90.7 ± 0.9	73.9 ± 1.0	50.0 ± 2.4	75.2 ± 2.0	780 ± 0
Bagging	62.9 ± 0.5	73.0 ± 0.0	43.8 ± 2.5	63.3 ± 0.9	75.1 ± 0.6	57.9 ± 1.7	55.2 ± 1.7	780 ± 0
QBC	65.4 ± 2.0	65.4 ± 10.9	56.6 ± 12.2	73.1 ± 5.8	72.4 ± 2.6	49.1 ± 9.9	54.5 ± 5.4	189 ± 32
CSeuil	62.0 ± 3.0	31.1 ± 35.6	23.5 ± 27.3	85.8 ± 16.3	66.2 ± 7.4	24.4 ± 28.1	25.3 ± 28.0	83 ± 87
CProba	58.5 ± 2.6	15.6 ± 27.7	14.8 ± 21.9	89.0 ± 17.1	62.5 ± 5.2	12.1 ± 22.4	15.7 ± 21.9	18 ± 15
Vote CSeuil	64.6 ± 4.8	33.6 ± 32.1	43.2 ± 38.5	93.0 ± 9.2	65.3 ± 5.6	17.6 ± 20.1	35.9 ± 35.9	88 ± 39
Vote CProba	61.4 ± 2.9	12.0 ± 21.6	36.3 ± 44.5	97.2 ± 6.3	61.7 ± 3.3	6.4 ± 12.7	23.5 ± 34.5	22 ± 7
Vote MC	73.7 ± 1.0	81.2 ± 1.2	84.6 ± 1.7	73.4 ± 2.5	66.5 ± 1.1	63.5 ± 2.1	70.7 ± 1.7	115 ± 2
MC	73.0 ± 1.7	80.3 ± 2.5	84.2 ± 2.5	72.6 ± 3.5	66.2 ± 2.1	63.0 ± 4.3	69.1 ± 3.6	115 ± 5
NB	69.9 ± 0.3	63.8 ± 0.4	93.2 ± 0.4	69.7 ± 0.6	72.7 ± 0.8	79.0 ± 0.9	52.1 ± 0.3	435 ± 0
AdaBoost	74.1 ± 0.9	76.9 ± 1.1	84.7 ± 1.6	73.9 ± 2.8	67.0 ± 1.4	70.3 ± 3.4	72.4 ± 2.5	435 ± 0
SVM	73.4 ± 0.6	75.9 ± 0.7	85.8 ± 0.6	88.3 ± 0.6	61.7 ± 0.6	47.1 ± 1.4	93.5 ± 0.7	435 ± 0
Bagging	70.0 ± 0.4	63.9 ± 0.6	93.3 ± 0.7	70.5 ± 0.9	72.4 ± 0.7	78.1 ± 0.9	52.4 ± 0.6	435 ± 0
QBC	67.9 ± 2.3	64.4 ± 2.8	88.9 ± 5.9	70.1 ± 5.7	67.2 ± 4.5	69.5 ± 11.4	52.6 ± 5.7	112 ± 12
CSeuil	62.6 ± 3.1	66.0 ± 7.7	84.0 ± 6.5	68.1 ± 14.1	61.6 ± 8.8	49.2 ± 30.2	41.4 ± 16.1	56 ± 12
CProba	56.6 ± 3.6	55.8 ± 6.8	85.8 ± 8.9	70.5 ± 21.8	57.3 ± 13.5	36.2 ± 37.3	27.2 ± 16.6	18 ± 5
Vote CSeuil	66.4 ± 1.7	64.9 ± 2.3	89.9 ± 3.3	76.3 ± 8.3	61.9 ± 4.1	53.3 ± 17.3	52.0 ± 5.2	58 ± 3
Vote CProba	60.1 ± 3.2	57.3 ± 1.9	92.0 ± 4.8	80.0 ± 14.6	55.4 ± 9.3	33.7 ± 31.1	41.3 ± 13.0	20 ± 2

TABLE 5.6 – Performances (moyennes et écart-types sur 50 initialisations aléatoires de E_{init}) à la fin du flux d'exemples des différents algorithmes sur l'apprentissage de l'indicateur de vitesse dans deux contextes, (K, centre) (tableau du haut), (P, extérieur) (tableau du bas) : dans l'ordre des colonnes, taux de bonne classification (TBC), rappel et précision pour chaque classe (R_{classe} et P_{classe}), et nombre d'exemples sélectionnés par les algorithmes (Nb Ex), exemples d'initialisation de E_{init} compris.

Comparaison des performances des algorithmes à la fin du flux

Tous les résultats de cette partie et de la suite sont obtenus par 50 apprentissages avec initialisation aléatoire. Remarquons tout d'abord qu'une part des "objectifs" de nos algorithmes sont remplis. Les performances de MC sont majoritairement meilleures que celles de son algorithme de base, NB (lorsque NB est meilleur sur le rappel ou la précision d'une classe, c'est au détriment de l'autre critère sur la même classe). Les performances de Vote MC, en moyenne et écart-type, sont dans tous les cas supérieures à MC.

Il apparaît que la tâche d'apprentissage est plus difficile dans le contexte (K, centre) que (P, extérieur)³⁷. Il apparaît aussi que Vote MC a de bonnes performances, dépasse légèrement AdaBoost mais est très nettement dépassé par SVM dans le contexte (K, centre), alors que ces trois algorithmes font jeu égal dans le contexte (P, extérieur). Il faut cependant noter que les très bonnes performances de SVM ne sont pas équilibrées sur toutes les classes. SVM favorise la classe MOY, très majoritaire en nombre d'exemples, au détriment des classes "extrêmes", MIN et MOY. C'est particulièrement marqué pour la classe MAX dans le contexte (P, extérieur). AdaBoost est plus équilibré, mais montre aussi des faiblesses pour la classe MAX, dans le contexte (K, centre).

Concernant les algorithmes de sélection de données, leurs performances sont très décevantes. Seul QBC tire son épingle du jeu, même s'il montre des faiblesses pour la classe MAX dans le contexte (K, centre). Les autres dégradent les performances de NB dans la plupart des critères. Le faible nombre d'exemples sélectionnés par ces algorithmes peut expliquer leur contre-performance. QBC en sélectionne nettement plus, se rapprochant de Vote MC. Il n'y a par contre pas de relation simple entre le nombre d'exemples sélectionnés et les performances, comme nos algorithmes le montrent.

Comparaison des courbes d'apprentissage des algorithmes

Nous étudions ensuite les courbes d'apprentissage des algorithmes, i.e. la représentation de leur performance en fonction de la taille du flux d'exemples. La taille du flux augmente de 5 exemples à chaque évaluation des algorithmes. Nous présentons le taux de bonne classification dans les deux contextes (cf figures 5.12), ainsi que les courbes d'apprentissage pour la classe MAX (rappel et précision) (cf figures 5.13 et figures 5.14) car cette classe semble poser problème à un certain nombre d'algorithmes. Les premiers résultats, pour des flux de taille inférieure à 100, 150 exemples, sont trop variables pour être interprétés. Nous n'avons pas représenté les écarts-types car ils apportent peu d'information supplémentaire par rapport aux valeurs à la fin du flux, indiquées dans le tableau 5.6. L'écart-type du taux de bonne classification pour chaque algorithme diminue "naturellement" lorsque le nombre d'exemples d'apprentissage augmente.

Pour le taux de bonne classification, il apparaît que Vote MC est quasiment toujours meilleur que MC, lui-même meilleur que NB. Par contre, Vote MC reste assez instable, en

37. Comme nous le décrivions plus tôt dans ce chapitre, il apparaît que notre problème d'apprentissage est difficile, même pour les meilleures méthodes disponibles.

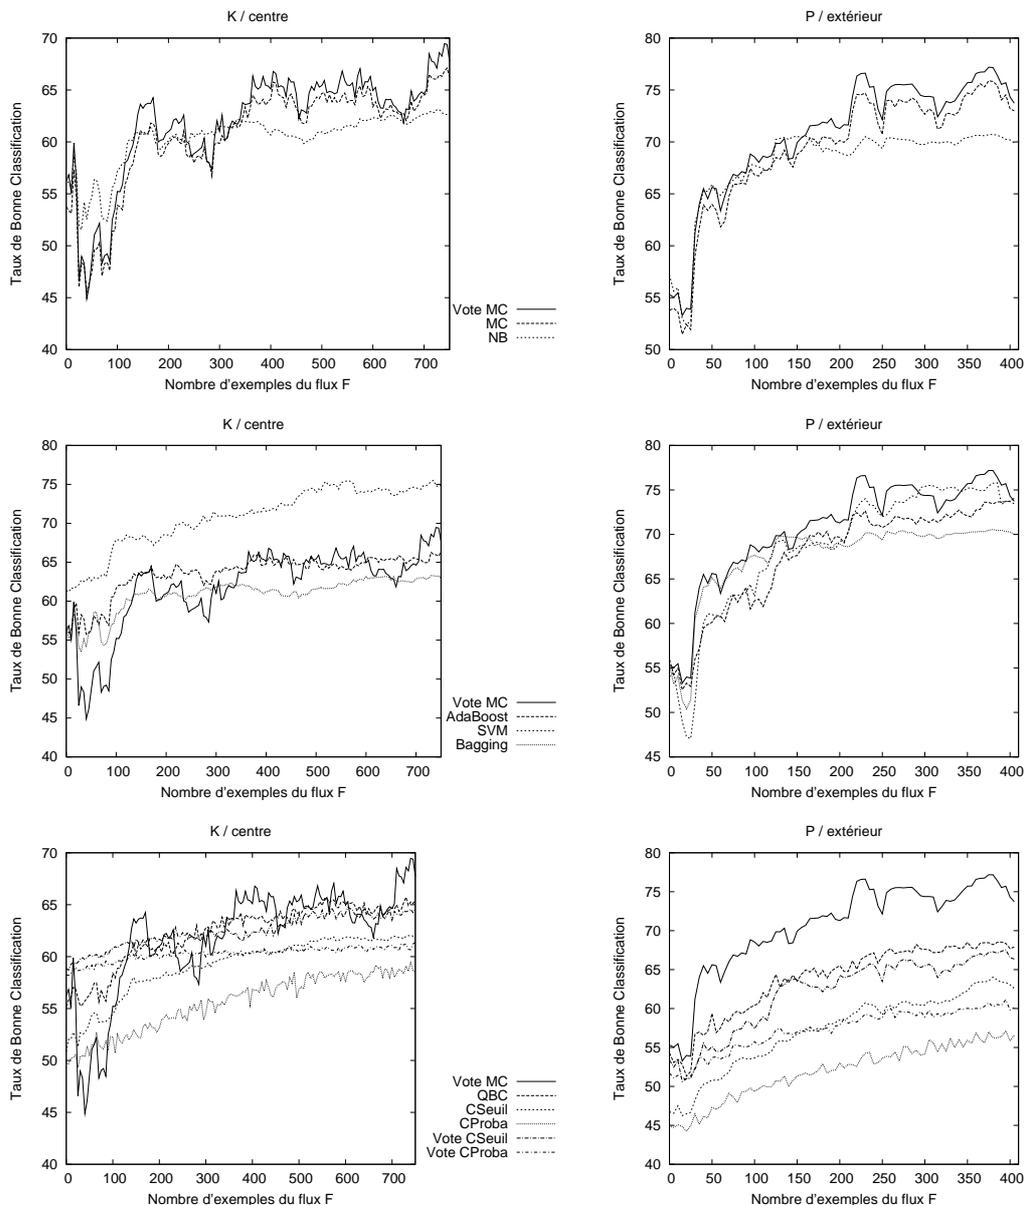


FIGURE 5.12 – Courbes d'apprentissage : représentation du taux de bonne classification en fonction de la taille du flux de données utilisé, pour le contexte (K, centre) (colonne de gauche) et le contexte (P, extérieur) (colonne de droite). Les algorithmes ne sont pas tous représentés sur une même figure pour leur lisibilité. Vote MC est présent sur toutes les figures. La première ligne correspond à nos algorithmes, MC et Vote MC, avec NB. La seconde ligne correspond aux algorithmes les plus performants, pour la plupart non-incrémentaux, Vote MC, AdaBoost, SVM et Bagging. La dernière ligne correspond aux algorithmes de sélection de données, Vote MC, QBC, CSeuil, CProba, Vote CSeuil et Vote CProba.

particulier dans le contexte (K, centre). Il est difficile de commenter les résultats de rappel et précision pour la classe MAX. Ces indicateurs sont en effet dépendants, et il apparaît bien que lorsque l'un augmente significativement, l'autre diminue. De même, l'ordre des

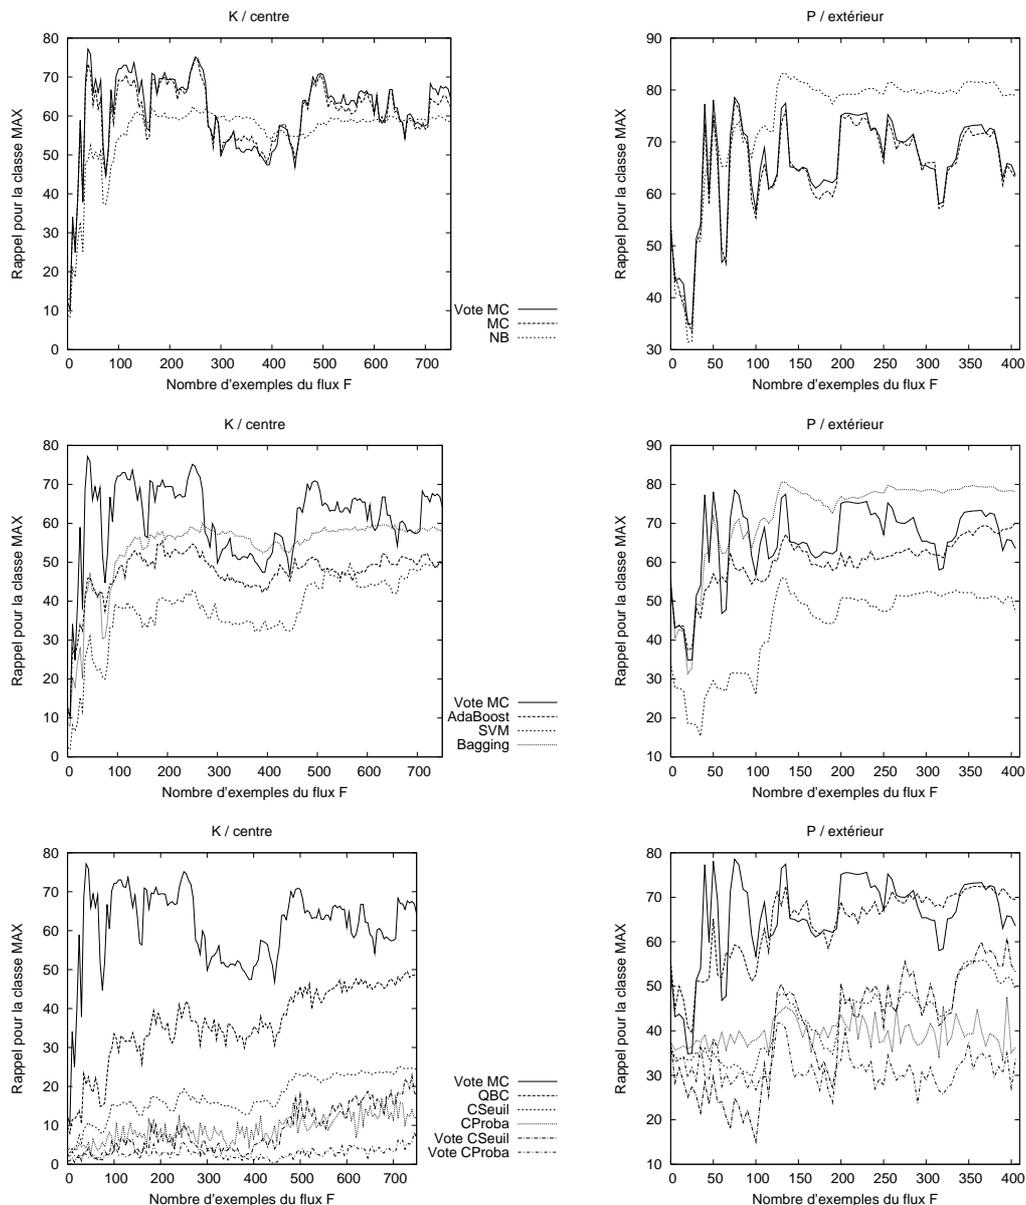


FIGURE 5.13 – Courbes d’apprentissage : représentation du rappel pour la classe MAX en fonction de la taille du flux de données utilisé, pour le contexte (K, centre) (colonne de gauche) et le contexte (P, extérieur) (colonne de droite). Les algorithmes sont répartis par ligne de la même façon que dans les figures 5.12.

algorithmes s’inverse selon que l’on considère le rappel ou la précision. C’est très clair dans le contexte (P, extérieur), dans lequel NB domine pour le rappel, alors que Vote MC et MC dominant pour la précision.

SVM a incontestablement les meilleures performances tout au long de l’apprentissage dans le contexte (K, centre), tandis que Vote MC, AdaBoost et Bagging sont proches. Les résultats sont plus serrés entre ces mêmes algorithmes dans le second contexte. Des conclusions plus claires peuvent être tirées en observant les courbes de rappel et précision.

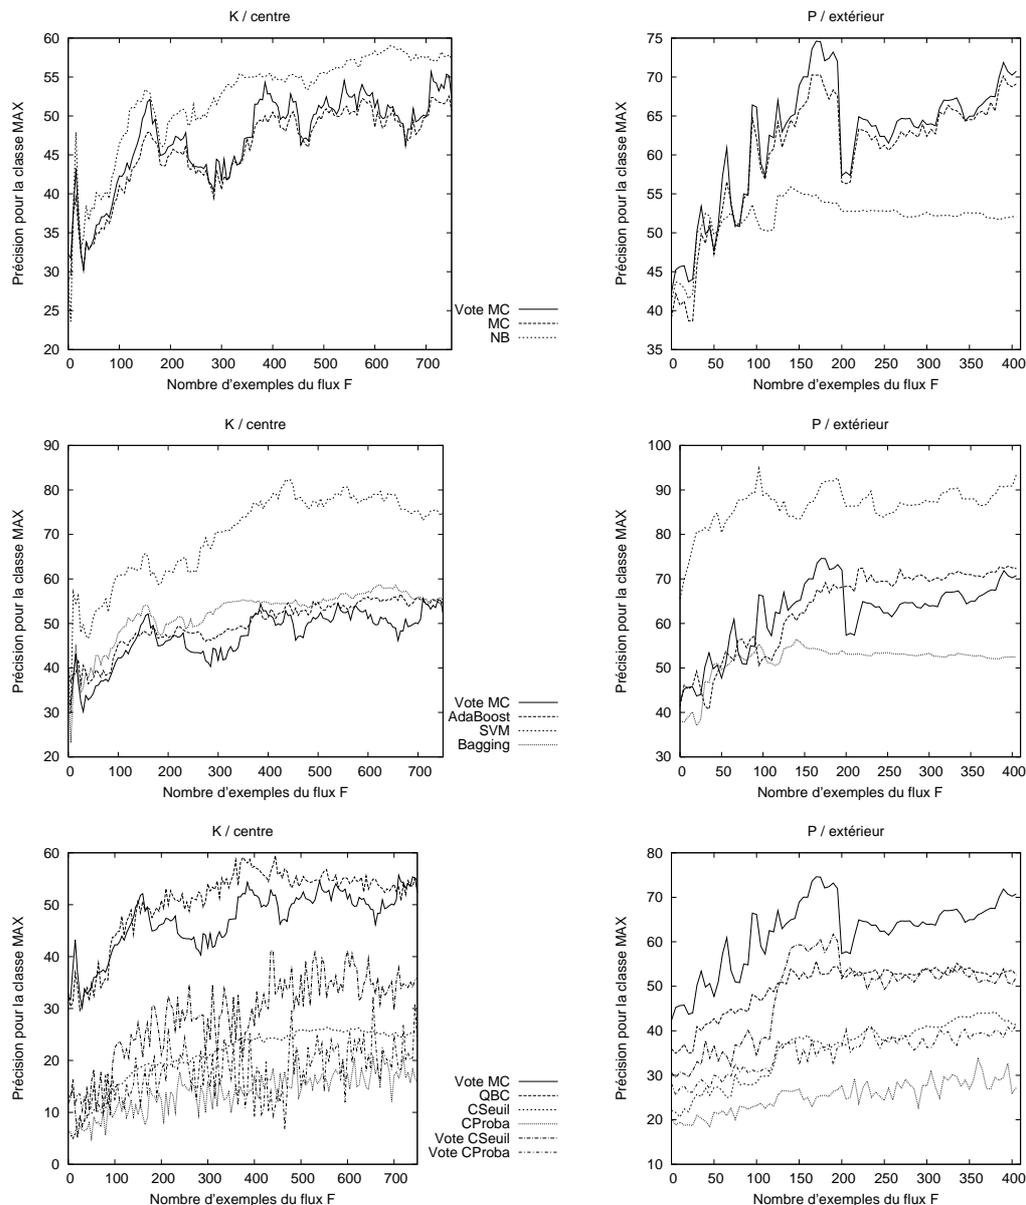


FIGURE 5.14 – Courbes d'apprentissages : représentation de la précision pour la classe MAX en fonction de la taille du flux de données utilisé, pour le contexte (K, centre) (colonne de gauche) et le contexte (P, extérieur) (colonne de droite). Les algorithmes sont répartis par ligne de la même façon que dans les figures 5.12.

Dans les deux contextes, plus fortement dans le contexte (K, centre), Vote MC a un très bon rappel, dépassé parfois par Bagging dont les performances sont proches de NB, tout en gardant une précision dans la moyenne des autres algorithmes hormis SVM, qui est nettement meilleur, au détriment du rappel.

Enfin, les algorithmes de sélection de données font bonne figure dans le contexte (K, centre) pour le taux de bonne classification, en particulier QBC, mais cette impression ne résiste pas à un examen de leurs performances détaillées par classe, comme sur la classe

MAX. Dans le contexte (P , extérieur), Vote MC a un taux de bonne classification nettement supérieur aux autres algorithmes de sélection de données pendant tout l'apprentissage. QBC est le seul algorithme qui a un rappel proche de Vote MC, mais en précision, Vote MC est nettement supérieur à tous ces algorithmes.

En conclusion, si Vote MC n'est pas le meilleur selon tous les critères, et est en particulier nettement moins bon que SVM dans un contexte, il a de bonnes performances en taux de bonne classification et par classe : aucune n'est particulièrement favorisée au dépens des autres. Il se montre aussi clairement comme étant le meilleur algorithme de sélection d'exemples dans un flux parmi ceux testés.

5.4.3 Conclusion

Il apparaît que l'algorithme développé Vote MC répond aux objectifs pour lesquels il a été développé, i.e. un algorithme incrémental qui améliore les performances des algorithmes classiques sur la tâche d'apprentissage d'un indicateur de sévérité, notre indicateur de vitesse. Il est en outre peu coûteux computationnellement. De plus, Vote MC est performant sur des problèmes classiques d'apprentissage pour lesquels il n'a pas été particulièrement conçu. Nous remarquons aussi les bonnes performances de l'algorithme non-incrémental VoteAlea MC sur les problèmes d'apprentissage classiques.

5.5 Perspectives et problèmes ouverts

Nous avons présenté une famille d'algorithmes génériques :

- l'algorithme de sélection de données dans un flux, comme MC,
- l'algorithme construisant un vote d'hypothèses produites par un algorithme de sélection de données dans un flux initialisé aléatoirement pour chaque hypothèse, comme Vote MC,
- l'algorithme construisant un vote d'hypothèses produites par un algorithme de sélection de données dans un flux dont l'ordre est tiré aléatoirement pour chaque hypothèse, comme Vote AleaMC.

Tous ces algorithmes sont définis par le critère de sélection des données, ainsi que l'algorithme d'apprentissage de base. A notre connaissance, nous avons testé tous les critères de sélection génériques, i.e. non spécifiques à une famille d'hypothèses. Il apparaît que le critère de sélection des exemples mal-classés par l'hypothèse courante donne les meilleurs résultats sur la plupart des problèmes classiques utilisés et dans notre problème d'indicateur de vitesse. Nous n'avons par contre pas présenté de résultats quant à d'autres algorithmes de base. Nous avons testé dans nos préliminaires d'autres algorithmes incrémentaux, et il est apparu que l'algorithme des classifieurs bayésiens est le plus sensible au critère MC, i.e. donne les meilleures performances en tant qu'algorithme de base. Il serait donc intéressant d'explorer l'espace des autres algorithmes incrémentaux en les croisant avec les différents critères de sélection d'exemples.

Il pourrait être aussi intéressant de travailler sur d'autres problèmes dans lesquels les données sont séquentielles. Une possibilité consisterait à convertir selon une technique classique des séries temporelles en flux d'exemples étiquetés, chaque exemple étant constitué des n dernières valeurs de la série, avec pour étiquette la valeur future à prédire.

Une prolongation naturelle à notre travail est d'envisager des méthodes pour traiter la qualité de l'apprentissage sur des périodes plus longues que ce que nous avons fait. Notre apprentissage traite une portion réduite de la base de données disponible. Il faudrait donc envisager des méthodes de suivi des performances sur toute cette base, dont certaines caractéristiques saisonnières ont forcément évolué pendant sa constitution. Nous avons déjà fait allusion à ce domaine bien identifié, celui de la détection de changement de concept ("concept drift"). Ces travaux impliquent de revenir sur l'hypothèse de stationnarité de l'environnement. Un scénario classique pour le traitement de ce problème consiste à suivre la qualité des hypothèses produites, et envisager des méthodes de mise à jour en cas de dégradation de leur qualité. (Vinot, 2004) consacre un chapitre à ce sujet et détaille trois types d'indicateur d'un changement de concept :

- des mesures de performances, comme le taux de bonne classification. Il faut disposer des étiquettes pour cet indicateur.
- des propriétés de l'hypothèse, comme la complexité des règles pour certaines hypothèses.
- la description des données, comme leur distribution.

Ces indicateurs sont en général utilisés pour adapter la taille d'une fenêtre glissante sur les derniers exemples pris en compte par l'hypothèse courante. Lorsque l'indicateur indique un changement de concept, la fenêtre est raccourcie, sinon elle est agrandie progressivement au maximum. La fenêtre peut être globale sur tous les exemples, ou dépendre de chaque exemple. Si l'oubli est difficile pour des algorithmes incrémentaux, il est possible d'envisager des méthodes duales de fenêtre glissante sur les hypothèses. Nous voyons une adéquation "naturelle", des liens entre les algorithmes incrémentaux, les algorithmes de sélection de données et les méthodes de combinaison d'hypothèses, qui doivent permettre en particulier de traiter les changements de concept. Des hypothèses sont apprises ou mises à jour sur les nouvelles données, et peuvent être combinées à des hypothèses plus anciennes, déterminées par une fenêtre glissante ajustable.

Des portes restent ouvertes dans notre problématique sur d'autres cadres d'apprentissage non-traditionnels, en particulier l'usage de toute l'information fournie par l'expert. Les classes de notre problème sont ordonnées. Nous n'avons cependant pas utilisé cette information. Des méthodes meilleures qu'une conversion simple en un problème de régression existent. Similaires aux codes correcteurs d'erreur et à notre proposition pour tenir compte des exemples aux étiquettes floues (cf partie 5.3.3), elles consistent à convertir un problème de classification à N_C classes ordonnées, en $N_C - 1$ problèmes de classification, et donnent de bons résultats (Frank et Hall, 2001). Ce n'était cependant pas le cas dans nos expériences. Une autre possibilité consiste à essayer d'apprendre directement et seulement un ordre sur les données, à partir de comparaisons d'exemples deux à

deux, information qui peut être plus facile à fournir par l'expert (Cohen *et al.*, 1999; Diez *et al.*, 2002; Fürnkranz et Hüllermeier, 2005).

Nous avons en outre envisagé que l'expert puisse donner des informations supplémentaires sur la qualité des informations. Comme nous l'avons déjà dit dans l'introduction de ce chapitre, il est très difficile de définir un cadre dans lequel l'expert serait bienveillant avec l'apprenant. Comment dans un tel cadre obtenir des résultats fiables et répétables ?

Résumé

- Nous avons présenté dans ce chapitre une solution au problème de l'apprentissage d'indicateur de sévérité qualifiant des interactions dans le trafic. La méthode proposée est générique quant à l'indicateur évalué, et nous avons travaillé particulièrement avec l'indicateur de vitesse nécessaire à notre travail.
- Les données sont étiquetées par un expert dont le jugement est imprécis et incertain. Il est en mesure de distinguer un petit nombre de niveaux de sévérité, i.e. de classes ordonnées, typiquement trois pour l'indicateur de vitesse. Nous modélisons son imprécision par des ensembles flous, et lui permettons de ne pas choisir lorsqu'il hésite entre deux classes.
- Les données, même enregistrées, se présentent sous la forme d'un flux, et nous voulons être en mesure d'utiliser les méthodes développées en ligne. Cela nous a poussé à étudier des algorithmes incrémentaux, i.e. permettant l'induction d'un classifieur en une seule passe sur un ensemble de données, avec des ressources limitées et pouvant être mis à jour sur de nouveaux exemples.
- Les classes de sévérité se chevauchent, et notre objectif est d'améliorer les performances des algorithmes classiques sur notre problème.
- Un algorithme incrémental nous permet de sélectionner les données qui apportent le plus d'information. Pour cela, il faut spécifier un critère de sélection des exemples. De tels critères dans le domaine de l'apprentissage actif permettent de sélectionner les exemples non-étiquetés. Nous les comparons à un critère sur les exemples étiquetés, consistant à choisir les exemples mal-classés par l'hypothèse courante (algorithme et critère appelés MC).
- Pour obtenir des hypothèses plus stables, nous combinons des hypothèses apprises sur le même flux de données et initialisées sur de petits ensembles différents (algorithme appelé Vote MC).
- Nous étudions les performances de nos algorithmes sur des problèmes d'apprentissage classiques, ainsi que sur notre problème d'apprentissage de l'indicateur de vitesse, dans deux contextes différents. Nous comparons nos algorithmes à d'autres algorithmes de sélection de données, ainsi que des algorithmes de références non-incrémentaux comme AdaBoost et SVM. L'algorithme de base utilisé si nécessaire est l'algorithme des classifieurs bayésiens naïfs. Vote MC est l'algorithme de sélection de données le plus performant sur la majorité des problèmes, en particulier pour l'indicateur de vitesse. Les algorithmes de référence sont souvent meilleurs, mais pas forcément significativement. Un algorithme de combinaison des hypothèses apprises par l'algorithme MC sur l'ensemble des données dans un ordre tiré aléatoirement donne de bons résultats sur les problèmes classiques.
- Les algorithmes présentés sont génériques et méritent d'être évalués sur d'autres problèmes, avec d'autres critères et algorithmes de base.

6

Analyse comparative de deux stratégies de régulation

Sommaire du chapitre

6.1	Les résultats	131
6.1.1	Présentation	131
6.1.2	Comparaisons	134
6.2	Conclusion	138
6.3	Limites et perspectives	139

6.1 Les résultats

Nous sommes maintenant en mesure de répondre à notre problématique de départ. Tous les modules de notre système ont été présentés et validés. Nous analysons l'impact de stratégies de régulation sur la sécurité en relevant et qualifiant selon les indicateurs de sévérité définis les durées d'interactions qui se sont déroulées sur le carrefour lorsque les stratégies comparées étaient appliquées, pendant des périodes de temps équivalentes pour toutes les stratégies. Nous avons déjà introduit la base des données disponibles pour notre étude dans la partie 3.2.4.

6.1.1 Présentation

Les contextes étudiés

Nous relevons les instants auxquels des interactions ont lieu sur la moitié nord du carrefour, i.e. les intersections P et K. Le nombre de contextes traités dépend de notre capacité à apprendre des hypothèses permettant la prédiction de l'indicateur de vitesse dans chaque contexte. Pour évaluer les performances de notre méthode d'apprentissage et vérifier

que nos résultats ne dépendent pas d'un seul contexte, nous avons travaillé sur l'indicateur de vitesse dans deux contextes, à savoir (K, centre) et (P, extérieur). Nous sommes donc en mesure d'estimer automatiquement l'indicateur de vitesse dans ces deux contextes. Le fait que P ne possède qu'une seule zone aval (cf figure 3.2) a des conséquences sur le déplacement des mobiles dans ces deux zones de conflits. Tous les mobiles venant du centre du carrefour et entrant dans la zone de conflit P doivent tourner à gauche, et auront donc une vitesse réduite dans cette zone de conflit. En amont, les mobiles venant de l'extérieur du carrefour et entrant dans la zone de conflit K passent ensuite normalement par la zone de conflit P¹. Ces mobiles, qui vont donc tourner à gauche dans la zone de conflit P, réduisent déjà leur vitesse dans la zone de conflit K. Lorsque nous avons essayé d'apprendre l'indicateur de vitesse pour les interactions qui mettent en jeu des mobiles dans les deux contextes (K, extérieur) et (P, centre), nous n'avons pu réussir à distinguer plus d'un niveau de sévérité pour cet indicateur. Pour les instants d'interaction détectés dans ces contextes, nous n'estimons donc que l'indicateur de proximité. Nous pouvons analyser tous les instants d'interaction des catégories étudiées dans les deux zones de conflits K et P, quelle que soit leur origine.

D'après les résultats de validation du module de détection des interactions (cf partie 4.4), nous pouvons faire confiance aux détections des interactions de la catégorie antagoniste. Pour la catégorie aval à l'arrêt, nous n'étudions les résultats que dans le contexte (K, centre). Nous traitons les interactions de la catégorie antagoniste dans son ensemble, par opposition au passage d'un mobile dans la zone de conflit lorsque la zone de stockage antagoniste est vide. Nous distinguons la sous-catégorie antagoniste en mouvement, qui seule contient des interactions critiques.

Les échantillons

Nous comparons CRONOS, la stratégie développée à l'INRETS dans le laboratoire CI (cf partie 2.1.3), à une stratégie de Référence (cf partie 3.2.4). Quelle que soit la stratégie appliquée, les instants d'interactions sont détectés dans les échantillons sélectionnés avec les mêmes règles, leur indicateur de proximité estimé selon la même méthode de calcul et leur indicateur de vitesse estimé avec les mêmes hypothèses, apprises sur des données indépendantes de ces échantillons et dont les performances sont proches sur des ensembles de données des deux stratégies. Nous traitons donc les données des deux stratégies comparées toutes choses égales par ailleurs.

Il faut s'assurer que les échantillons eux-mêmes ont des caractéristiques comparables. Nous nous sommes contraints pour cela à des échantillons dans les mêmes conditions de trafic, aux mêmes horaires, pour avoir une grande similitude dans les origines-destinations des mobiles. Les conditions de trafic sont définies selon la demande totale reconstituée sur le carrefour. Nous avons choisi d'étudier les conditions de trafic de "pointe" dans l'horaire 8h à 9h et "fluide" dans l'horaire 10h à 11h (cf tableau 6.1). Ces deux conditions

1. Les mouvements de tourne à droite sont interdits dans le carrefour.

Lieu	Origine	Pointe	Fluide
P	extérieur	642 ± 20 / 656 ± 31 (641 ± 18 / 642 ± 34)	496 ± 34 / 500 ± 33 (491 ± 30 / 503 ± 27)
	centre	501 ± 11 / 478 ± 19 (507 ± 19 / 466 ± 26)	312 ± 28 / 296 ± 20 (309 ± 33 / 302 ± 22)
K	extérieur	351 ± 17 / 331 ± 4 (358 ± 23 / 330 ± 4)	236 ± 14 / 227 ± 12 (247 ± 26 / 233 ± 20)
	centre	1306 ± 96 / 1279 ± 93 (1309 ± 76 / 1315 ± 95)	719 ± 84 / 717 ± 21 (762 ± 96 / 771 ± 73)

TABLE 6.1 – Le tableau contient les moyennes et écarts-types sur les échantillons traités (et sur tous les échantillons disponibles entre parenthèse) des demandes par contexte (lieu, origine), stratégie (dans l'ordre Référence / CRONOS) et condition de trafic. Les échantillons traités sont choisis par lieu et condition de trafic tels que la différence relative à la stratégie de Référence entre les moyennes horaires des demandes sous les deux stratégies soit inférieure à 5 % sur les deux entrées. Pour les deux stratégies, il y a 5 échantillons par contexte (lieu, origine) et condition de trafic, hormis dans le lieu P en fluide, dans lequel 7 échantillons peuvent être utilisés.

de trafic sont les plus différentes disponibles dans les données, hormis la condition "très fluide", écartée car trop atypique.

Si nous voulons comparer les stratégies toutes choses égales par ailleurs, nous devons prendre en compte le facteur de la demande de trafic, qui a un impact sur la quantité d'événements dans le trafic. Le nombre d'interactions dans le trafic augmente avec le nombre de mobiles. Nous avons expliqué pourquoi nous ne calculons pas de taux d'interactions similairement aux taux d'accidents (cf partie 2.3.1). Pour les interactions de la catégorie antagoniste, il faut tenir compte conjointement des demandes sur les deux entrées d'une zone de conflit (Hauer *et al.*, 1988). Parmi les échantillons disponibles pour chaque stratégie et condition de trafic, nous en avons choisi le plus grand nombre (le même sous chaque stratégie), de sorte que la différence relative à la stratégie de Référence entre les moyennes horaires des demandes sous les deux stratégies soit inférieure à 5 % sur les deux entrées (cf tableau 6.1). Pour les deux stratégies, il y a 5 échantillons par contexte (lieu, origine) et condition de trafic, hormis dans le lieu P en fluide, dans lequel 7 échantillons peuvent être utilisés. Lorsque nous comparons les demandes moyennes des échantillons choisis à tous les échantillons disponibles avec les mêmes caractéristiques, il apparaît que nos échantillons ne sont pas particuliers, hormis dans le contexte (K, centre). Il faut cependant noter que nous étions contraints dans le choix des échantillons par les conditions météorologiques.

6.1.2 Comparaisons

Interprétation des résultats

Comme nous l'avons décrit dans la partie 3.3.4, en supposant les autres facteurs égaux, nous comparons les expositions des mobiles sous les deux stratégies étudiées pour tous les contextes (lieu, origine), à l'aide des éléments suivants.

- les *expositions totales*, i.e. les durées d'interaction indépendamment des niveaux de sévérité,
- les *proportions* d'exposition totale pour la catégorie antagoniste en mouvement, sur l'exposition totale pour toute la catégorie antagoniste, ainsi que les proportions d'exposition totale pour la catégorie antagoniste, sur la durée totale de situations de passage d'un mobile dans la zone de conflit, que des mobiles dans la zone de stockage antagoniste soient présents ou non,
- selon les indicateurs de sévérité disponibles, les *distributions de l'exposition* et des *pourcentages d'exposition*, i.e. l'exposition par niveau de sévérité divisée par l'exposition totale,
- un *test statistique* pour déterminer s'il y a une différence significative entre les distributions. Le test de Kolmogorov-Smirnov (KS), utilisé dans (Svensson, 1998), indique si deux distributions appartiennent à la même distribution, i.e. si elles sont égales ("hypothèse nulle"). Ce test consiste, à partir des fonctions de répartition normalisées des deux distributions comparées, à calculer les différences en chaque point des fonctions de répartition, et à comparer la valeur absolue maximale des différences à une valeur tabulée selon les expositions totales. Nos tests utilisent un niveau de confiance de 0.95.

Nous analysons dans un premier temps l'exposition totale, puis les distributions selon les indicateurs de sévérité.

Les expositions totales

Nous étudions dans un premier temps les expositions totales sous les deux stratégies comparées, dans tous les contextes et conditions de trafic. Le tableau 6.2 indique sous quelle stratégie la différence relative d'exposition totale par rapport à la stratégie de Référence dépasse 5 % et 20 %. Pour commencer, nous faisons quelques remarques générales qui ne concernent pas des différences entre stratégies. Les expositions sont plus faibles en trafic fluide qu'en trafic dense. Nous avons constaté que dans chaque contexte et condition de trafic, pour les deux stratégies, l'exposition est nettement plus grande dans la catégorie antagoniste que dans la catégorie antagoniste en mouvement. Lors d'interactions de la catégorie antagoniste, les mobiles dans la zone de stockage antagoniste sont la plupart du temps à l'arrêt dans une file d'attente, ce qui explique les différences d'exposition. Les proportions d'interactions de la catégorie antagoniste en mouvement parmi l'ensemble des interactions de la catégorie antagoniste sont plus importantes en trafic fluide qu'en trafic de pointe pour tous les contextes et les deux stratégies. Ces pro-

Lieu	Origine	Catégorie	Pointe	Fluide
P	extérieur	antagoniste	686 / 644 : R	209 / 272 : C*
		proportion	25.8 % / 26.9 %	38.8 % / 42.1 %
		antagoniste en mouvement	176 / 173 : -	81 / 114 : C*
	centre	antagoniste	627 / 664 : C	346 / 427 : C*
		proportion	12.1 % / 13.2 %	12.6 % / 15.4 %
		antagoniste en mouvement	75 / 87 : C	43 / 65 : C*
K	extérieur	antagoniste	371 / 225 : R*	110 / 97 : R
		proportion	35.4 % / 45.6 %	39.4 % / 47.5 %
		antagoniste en mouvement	131 / 102 : R*	43 / 46 : C
	centre	antagoniste	1153 / 1094 : R	388 / 384 : -
		proportion	8.8 % / 9.0 %	13.2 % / 17.1 %
		antagoniste en mouvement	102 / 98 : -	51 / 65 : C*

TABLE 6.2 – Ces tableaux indiquent pour chaque contexte (zone de conflit P en haut et K en bas) et condition de trafic (pointe et fluide), les expositions totales par heure, et les proportions d'exposition totale pour la catégorie antagoniste en mouvement sur l'exposition totale pour la catégorie antagoniste (dans l'ordre Référence / CRONOS). La lettre désigne sous quelle stratégie la différence relative d'exposition totale par rapport à la stratégie de Référence est supérieure à 5 %. Une étoile * indique une différence relative supérieure à 20 %.

portions sont aussi systématiquement plus faibles pour l'origine centre que pour l'origine extérieur, ce qui, outre les différences de trafic, est lié aux données linéaires fournies par le traitement d'image sur les tronçons d'entrée du carrefour qui indiquent plus fréquemment de l'arrêt complet que pour des zones du centre du carrefour, plus sujettes au bruit. Ce n'est cependant pas gênant pour les comparaisons des stratégies dans chaque contexte. Ces observations sont conformes à nos attentes.

La situation est contrastée entre les deux zones de conflit. La stratégie de Référence a les expositions totales les plus importantes dans la zone K, pour les deux conditions de trafic, hormis la catégorie antagoniste en mouvement en fluide. CRONOS a les expositions totales les plus importantes dans la zone P dans les deux conditions de trafic, hormis pour l'origine extérieur en pointe.

Les proportions d'expositions Concernant les proportions d'exposition pour la catégorie antagoniste en mouvement sur l'exposition pour la catégorie antagoniste, nous remarquons une faible mais systématique supériorité en faveur de CRONOS, plus large dans le contexte (K, extérieur) en pointe (cf tableau 6.2).

Nous présentons des résultats en fin de thèse prenant en compte les situations de passage d'un mobile dans la zone de conflit lorsque la zone de stockage antagoniste est vide. Nous calculons la proportion d'exposition pour la catégorie antagoniste sur la durée cu-

Lieu	Origine	Catégorie	Pointe	Fluide
P	extérieur	passage	1001 / 1000 :-	713 / 831 : C
		proportion	68.5 % / 64.5 %	29.4 % / 32.8 %
	centre	passage	809 / 916 : C	489 / 644 : C
		proportion	77.4 % / 72.5 %	70.7 % / 66.2 %
K	extérieur	passage	620 / 528 : R	269 / 299 : C
		proportion	59.9 % / 42.6 %	41.0 % / 32.5 %
	centre	passage	1373 / 1332 :-	671 / 758 : C
		proportion	84.0 % / 82.1 %	57.8 % / 50.7 %

TABLE 6.3 – Ces tableaux indiquent dans chaque contexte (zone de conflit P en haut et K en bas) et condition de trafic (pointe et fluide), les instants de passage d'un mobile dans la zone de conflit, que des mobiles soient présents dans la zone de stockage antagoniste ou pas, et la proportion d'exposition pour la catégorie antagoniste sur la durée cumulée de passage dans la zone de conflit (dans l'ordre Référence / CRONOS).

mulée des passages d'un mobile dans la zone de conflit, que des mobiles soient présents ou non dans la zone de stockage antagoniste. D'après le tableau 6.3, nous observons que cette proportion est plus élevée sous la stratégie de Référence dans tous les contextes et conditions de trafic, hormis (P, extérieur) en fluide.

Les distributions d'exposition selon les indicateurs de sévérité

Nous analysons les distributions d'exposition selon les indicateurs de sévérité dans les différents contextes disponibles : 2 zones de conflit, K et P, avec leurs deux origines possibles, extérieur et centre, pour la catégorie antagoniste et la catégorie antagoniste en mouvement seule, dans les figures 6.1 à 6.12. Les valeurs faibles de l'indicateur de sévérité sont les plus sévères. Sur l'axe des abscisses des courbes, la sévérité est toujours décroissante.

Pour chaque contexte et condition de trafic, nous présentons les distributions des expositions selon chaque indicateur indépendamment, et les distributions des pourcentages d'exposition correspondantes si le test KS est rejeté². Nous résumons notre analyse des courbes des distributions présentées ici dans le tableau 6.4. Nous indiquons pour quelle stratégie l'exposition totale est la plus importante, puis analysons les distributions d'exposition selon les indicateurs de sévérité. Pour chaque indicateur séparément, nous désignons la stratégie pour laquelle l'exposition est la plus importante pour tous les niveaux de l'indicateur de sévérité, ou au moins les valeurs les plus sévères (à coté de la notation "Expo"). Nous indiquons aussi d'après les distributions des pourcentages d'exposition la stratégie pour laquelle la proportion d'interactions les plus sévères est la plus élevée, si l'hypothèse nulle du test KS est rejetée (à coté de la notation "Pct" pour pourcentage). Nous disons qu'une stratégie "domine" respectivement en exposition ou en pourcentage d'exposition.

2. Etudier les distributions selon chaque indicateur indépendamment est suffisant pour tirer nos conclusions.

Lieu	Origine	Catégorie	Pointe	Fluide
P	extérieur	antagoniste	Expo R (P) Expo R , Pct R (V) Expo C , Pct C	Expo C* (P) Expo C, Pct - (V) Expo C, Pct C
		antagoniste en mouvement	Expo - (P) Expo R, Pct R (V) Expo C, Pct -	Expo C* (P) Expo C, Pct - (V) Expo C, Pct -
	centre	antagoniste	Expo C (P) Expo C, Pct -	Expo C* (P) Expo C, Pct C
		antagoniste en mouvement	Expo C (P) Expo C, Pct -	Expo C* (P) Expo C, Pct -
K	extérieur	antagoniste	Expo R* (P) Expo R, Pct -	Expo R (P) Expo R, Pct -
		antagoniste en mouvement	Expo R* (P) Expo R, Pct -,	Expo C (P) Expo C, Pct -
	centre	antagoniste	Expo R (P) Expo R, Pct R (V) Expo C, Pct C	Expo - (P) Expo R, Pct R (V) Expo -, Pct -
		antagoniste en mouvement	Expo - (P) - (V) -	Expo C* (P) Expo C, Pct - (V) Expo C, Pct -

TABLE 6.4 – Ces tableaux indiquent pour chaque contexte (zone de conflit P en haut et K en bas) et condition de trafic (pointe et fluide) un résumé de notre analyse. La première ligne rappelle la stratégie qui a le plus d'exposition totale, avec une différence relative par rapport à la stratégie de Référence supérieure à 5 % ou 20 % avec une étoile *. Les indicateurs de sévérité sont désignés par P pour la proximité, V pour la vitesse. "Expo" indique quelle stratégie a l'exposition totale la plus grande, pour tous les niveaux ou au moins les plus sévères. "Pct" indique la stratégie pour laquelle la proportion d'interactions les plus sévères est la plus élevée, si l'hypothèse nulle du test KS est rejetée. R désigne la stratégie de Référence, C, CRONOS et "-" l'absence de différence significative entre les deux stratégies.

Indicateur de proximité Les résultats en exposition pour l'indicateur de proximité sont similaires à ceux pour l'exposition totale. Il apparaît que la stratégie de Référence domine dans la plupart des contextes de la zone K, hormis pour la catégorie antagoniste en mouvement en condition de trafic fluide (cf figures 6.8 et 6.9). CRONOS domine la plupart des contextes de la zone P, hormis pour l'origine extérieur en condition de trafic de pointe (cf figures 6.4 et 6.5). Lorsque nous examinons les distributions des pourcentages d'exposition, ils sont en accord avec les résultats précédents sur les distributions des expositions.

Indicateur de vitesse Concernant l'indicateur de vitesse, CRONOS domine dans tous les contextes en exposition et pourcentage, même lorsque la stratégie de Référence a une exposition totale plus importante, dans les contextes (K, centre, antagoniste) pour les deux conditions de trafic et (P, extérieur) en pointe (cf figures 6.2, 6.8, et 6.4). Les interactions supplémentaires sous la stratégie de Référence se concentrent alors dans les niveaux

moins sévères de l'indicateur de vitesse (par exemple dans le contexte (P, extérieur, antagoniste) en pointe, cf figure 6.4).

Conditions de trafic Des différences significatives en pointe disparaissent en fluide, comme dans les contextes (K, centre, antagoniste) pour l'indicateur de vitesse (cf figures 6.2 et 6.8) et (P, extérieur, antagoniste) pour l'indicateur de proximité (cf figures 6.4 et 6.10), ce qui est lié en partie à la baisse des expositions dans ces contextes qui rend l'hypothèse nulle du test KS plus difficile à rejeter. La domination pour les expositions totales et la distribution selon l'indicateur de proximité évolue de la stratégie de Référence vers CRONOS dans les contextes (P, extérieur), (K, extérieur, antagoniste en mouvement) et (K, centre, antagoniste en mouvement). Il est ainsi difficile de lier l'impact des deux stratégies de régulation aux conditions de trafic. Le clivage selon les deux zones de conflits traitées semble plus pertinent.

La catégorie aval à l'arrêt

Nous étudions les interactions de la catégorie aval à l'arrêt uniquement dans le contexte (K, centre) (cf figure 6.13), selon l'indicateur de vitesse. La stratégie de Référence domine, en exposition totale, ainsi que selon l'indicateur de vitesse. Les expositions sont faibles, mais le test KS indique une différence entre les distributions d'expositions. Dans les autres contextes, nous ne pouvons tirer aucune conclusion. Les expositions sont trop faibles en fluide. Indépendamment des problèmes de validation, il n'y a aucune différence significative entre les deux stratégies, en terme d'exposition et de pourcentage d'exposition dans les contextes (K, extérieur) et (P, centre). Il y a des différences dans le contexte (P, extérieur), mais les résultats de validation sont trop mauvais pour les prendre en compte.

6.2 Conclusion

Nous avons tâché de limiter par le choix des échantillons traités l'influence de la demande et nous tirons les conclusions suivantes. La stratégie de Référence crée globalement plus d'interactions dans la zone de conflit K. CRONOS crée globalement plus d'interactions dans la zone de conflit P.

Les résultats selon l'indicateur de proximité suivent ceux obtenus sur les expositions globales. Selon l'indicateur de vitesse, les interactions sous la stratégie CRONOS présentent des valeurs plus sévères en pourcentages d'exposition et en exposition, même dans des situations dans lesquelles l'exposition totale est plus importante pour la stratégie de Référence. Il apparaît donc que CRONOS implique une proportion plus élevée d'instantanés d'interactions dans la classe des vitesses maximales. Il faut remarquer en outre que l'exposition plus importante avec la classe des vitesses maximales sous CRONOS pourrait expliquer les plus faibles expositions totales dans certains contextes. Si les mobiles se déplacent plus vite, ils passent moins de temps dans la zone de conflit, ce qui peut

diminuer l'exposition mesurée. D'autres facteurs peuvent expliquer ce résultat comme une plus faible proportion de véhicules en interaction.

La supériorité constante de CRONOS dans les proportions d'interactions antagoniste en mouvement est en accord avec la constatation que CRONOS diminue le temps d'attente global des mobiles sur le carrefour en réduisant les files d'attente. Ceci peut aussi expliquer les différences entre le trafic dense et le trafic fluide. Il apparaît par contre que la stratégie de Référence implique une proportion d'interactions de la catégorie antagoniste plus importante que CRONOS. Relativement à un passage dans la zone de conflit, il est plus probable que des mobiles soient présents dans la zone de stockage antagoniste sous la stratégie de Référence que sous CRONOS.

D'après nos critères d'une stratégie favorisant la sécurité, les stratégies exposent les mobiles plus longtemps à des situations d'interactions chacune sur une zone de conflit, P pour CRONOS et K pour la stratégie de Référence. Les interactions sont souvent plus sévères sous CRONOS, en particulier en vitesse, reflétant vraisemblablement le caractère plus fluide de la situation. Il faut souligner en ce qui concerne Cronos que le critère optimisé dans la version testée de cette stratégie est la minimisation du temps d'attente, donc un objectif de régulation orienté fluidité et non sécurité ; seules les contraintes sur les durées et les agencements des feux sont imposées à la stratégie à des fins sécuritaires. Enfin, en l'absence des interactions les plus sévères et du lien des interactions étudiées à l'accident, les différences constatées ne nous permettent pas de conclure quant à l'impact des stratégies de régulation sur le risque.

6.3 Limites et perspectives

Nous ne pouvons, à l'instar des travaux de Å. Svensson, avoir une image complète des interactions dans une intersection et tirer des conclusions quant à la sécurité du carrefour étudié. Il nous manque essentiellement la détection des interactions les plus sévères, i.e. se déroulant entre des mobiles dans une même zone, et l'estimation de leur sévérité. Nous détectons essentiellement des interactions qui peuvent être qualifiées de "normales", i.e. peu sévères, très fréquentes et parfaitement gérées par les usagers impliqués. Certains de nos choix comme les hypothèses sur la couleur des feux et la vitesse des mobiles dans la zone de stockage antagoniste s'appuient même sur le fait que la plupart des interactions sont peu sévères.

Notre approche pour la modélisation des interactions est générique et pourrait être adaptée à des intersections plus complexes, afin de comparer avec une méthode similaire la sévérité des interactions qui s'y déroulent. Notre approche s'adapte directement à toute combinaison d'intersection de routes à sens uniques, comme le carrefour expérimental. Le point crucial est la modélisation des interactions dans une intersection de routes à double sens. Il est possible de généraliser notre approche qui consiste à étudier les conditions de passage d'un mobile dans une intersection. Selon la position des mobiles protago-

nistes, de nouvelles catégories apparaîtront. La méthode d'interprétation des expositions relevées peut être transposée dans les contextes de l'intersection.

Dans la présente étude, nous comparons des interactions en un même lieu, à partir de données provenant des mêmes capteurs. Il serait plus compliqué de comparer les interactions se déroulant dans des carrefours différents, comme pour les différentes sous-intersections du carrefour expérimental. Il serait nécessaire de s'assurer en particulier de la comparabilité des mesures de sévérité entre les différents lieux.

Il serait intéressant d'étudier complètement l'impact des paramètres et plus généralement des choix d'implémentation des modules sur l'analyse du risque menée dans ce chapitre, comme les seuils sur les distances entre les mobiles étudiés et la ligne de feu, ainsi que sur les tailles des formes. Les seuils sur les tailles des formes ont été ajustés pour minimiser les erreurs de détection. Etant donné les problèmes pour la catégorie aval à l'arrêt, il faudrait développer d'autres méthodes pour pouvoir les étudier de façon fiable. Si les seuils sur les distances changeaient, nous pensons que les différences entre les stratégies étudiées, mises en évidence par ce travail et les catégories d'interactions étudiées, ne seraient pas remises en cause de façon significative. L'intervalle de l'indicateur de proximité serait par exemple peu remis en cause, puisque dans chaque contexte, la valeur la plus sévère de chaque indicateur de proximité est retenue.

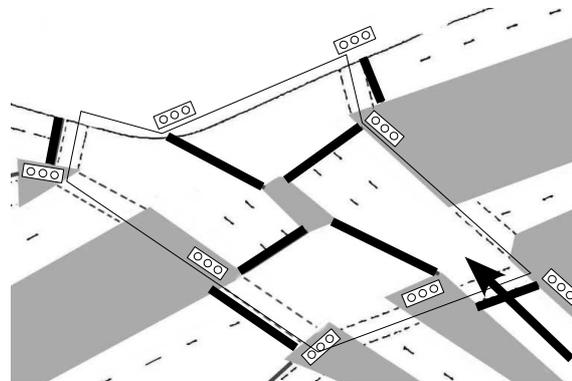
Concernant l'analyse de la base, il est important de limiter les influences des facteurs autres que les stratégies de régulation, en particulier la demande. Nous avons d'autres idées d'interprétation des données. La sortie du système constitue une séquence temporelle de détections d'interactions avec leur contexte et leurs indicateurs de sévérité. Ces séquences présentent des régularités liées aux cycles des feux et donc aux stratégies. Ces séquences pourraient être automatiquement analysées pour exhiber des séquences caractéristiques du fonctionnement des stratégies de régulation, des intersections, du carrefour selon les conditions de trafic.

Une autre possibilité consisterait à étudier les interactions par "période". Les interactions, en particulier les plus nombreuses, celles de la catégorie antagoniste, ont lieu souvent consécutivement ou à des instants proches. Ces périodes d'interaction par contexte pourraient être qualifiées selon leur temps global, et un résumé des valeurs prises par les indicateurs de sévérité de ces interactions. Les résultats seraient a priori moins détaillés, mais les performances en qualification de ces périodes pourraient être meilleures que celles de notre système.

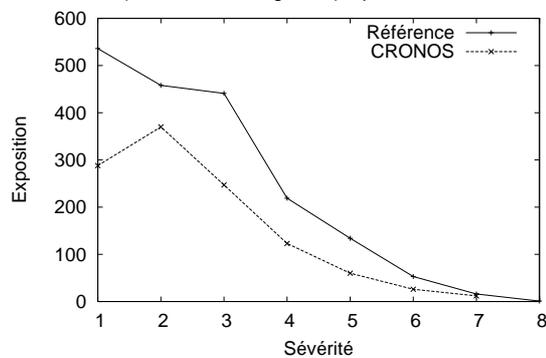
Enfin, une perspective intéressante pourrait consister à concevoir des stratégies de régulation et des carrefours minimisant les interactions que nous avons étudiées, i.e. limiter la mise en présence de mobiles d'origines différentes. Des carrefours très étendus et complexes sont développés aux Etats-Unis pour limiter les points de conflit entre flux antagonistes de mobiles. Des stratégies innovantes basées sur nos principes pourraient probablement y être mises en œuvre.

Résumé

- Nous relevons à chaque instant par contexte les interactions et les qualifions selon les deux indicateurs de sévérité (selon leur disponibilité), dans deux zones de conflit, P et K, soit la moitié du carrefour étudié.
- Toutes choses égales par ailleurs, nous comparons les expositions dans deux conditions de trafic, en pointe et fluide, sous les deux stratégies, la stratégie de Référence et CRONOS. La demande n'est cependant pas toujours la même pour les échantillons étudiés.
- Nous comparons les deux stratégies selon les expositions totales, les distributions d'exposition et les distributions des pourcentages d'exposition, avec un test statistique d'égalité.
- Nous mettons en évidence des différences entre les stratégies quant à leur impact sur la sévérité des interactions. La stratégie de Référence expose plus longtemps les usagers à des interactions dans la zone de conflit K, et CRONOS expose plus longtemps les usagers à des interactions dans la zone de conflit P. Selon l'indicateur de vitesse, les interactions sont proportionnellement plus sévères sous CRONOS.



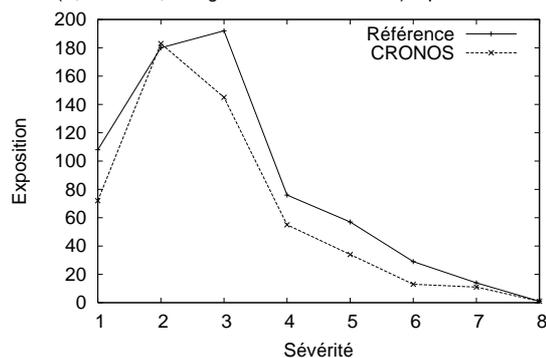
(K, extérieur, antagoniste) – pointe – Proximité



antagoniste : Test KS accepté

 $Exposition_{Référence} = 1858$, $Exposition_{CRONOS} = 1126$

(K, extérieur, antagoniste en mouvement) – pointe – Proximité



antagoniste en mouvement : Test KS accepté

 $Exposition_{Référence} = 657$, $Exposition_{CRONOS} = 514$

FIGURE 6.1 – Courbes d'exposition en fonction de l'indicateur de proximité dans le contexte (K, extérieur) en pointe pour les catégories antagoniste (au milieu, avec la distribution des pourcentages d'exposition) et antagoniste en mouvement (en bas), pour les 5 échantillons traités. Les expositions totales et tests KS sont aussi indiqués.

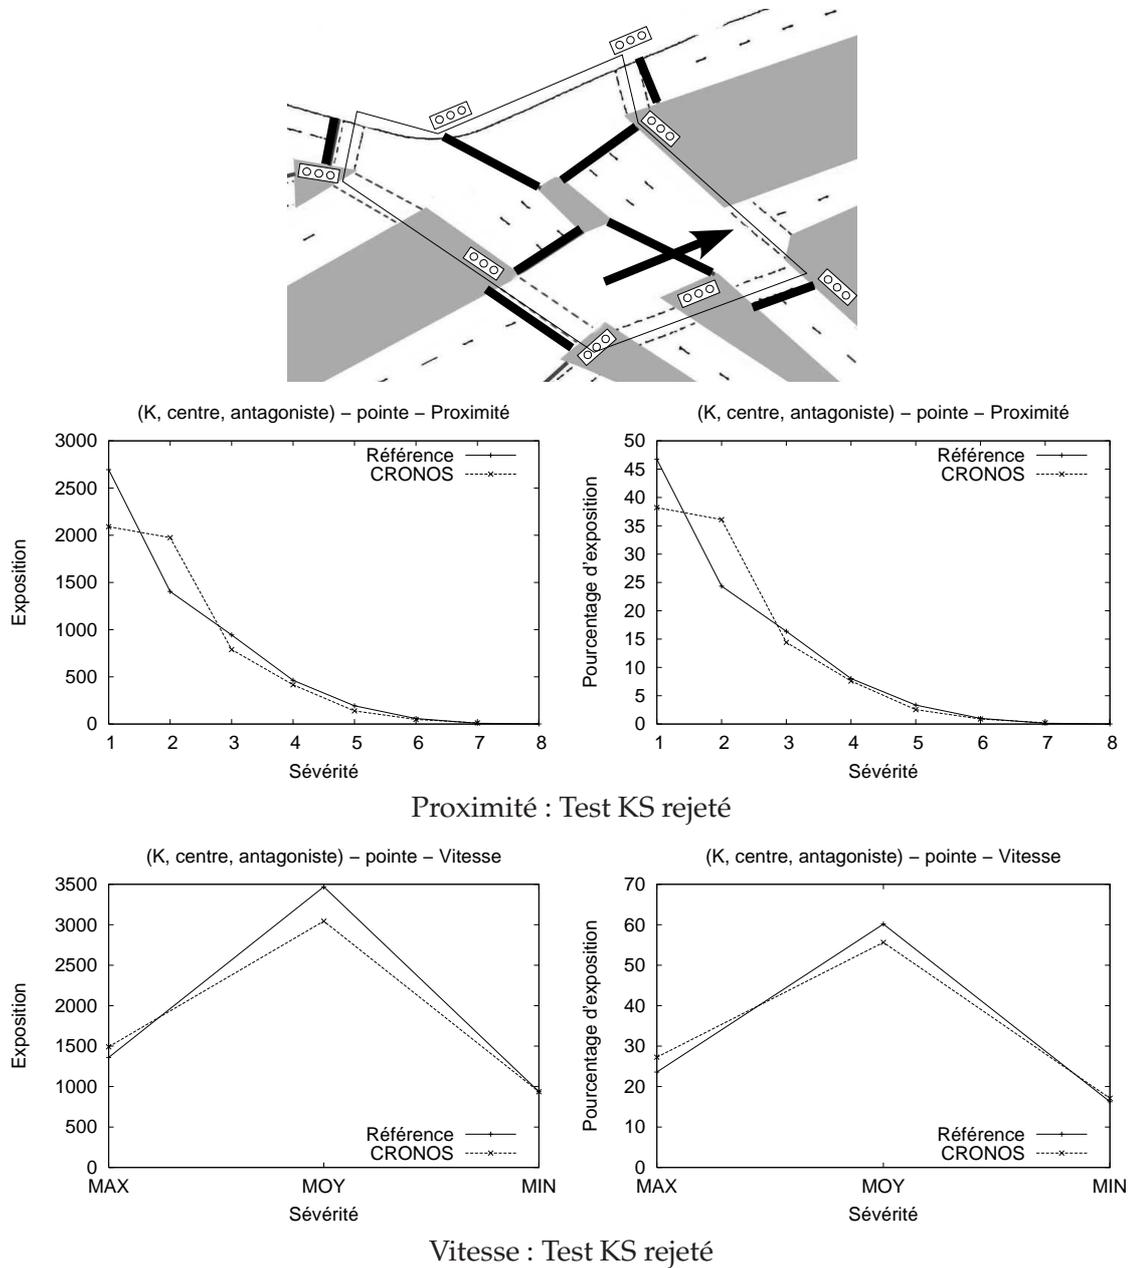
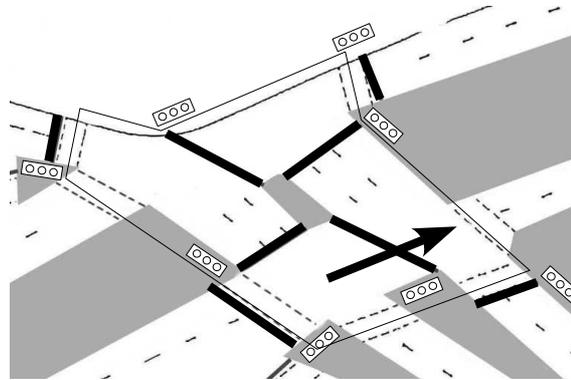
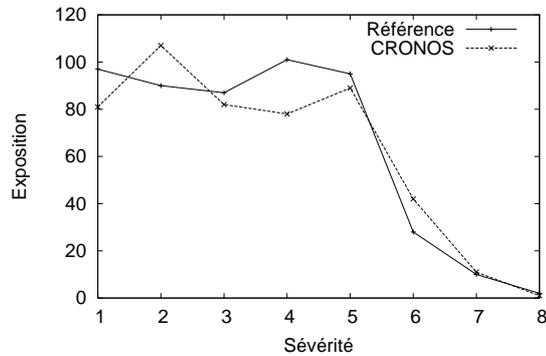


FIGURE 6.2 – Courbes d'exposition en fonction des indicateurs de sévérité, dans le contexte (K, centre, antagoniste) en pointe : exposition en fonction de chaque indicateur, Proximité au milieu, Vitesse en bas, avec les distributions des pourcentages d'exposition, pour les 5 échantillons traités. Les expositions totales et tests KS pour chaque indicateur sont aussi indiqués.

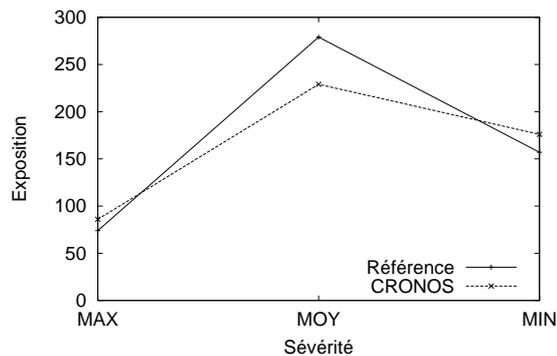


(K, centre, antagoniste en mouvement) – pointe – Proximité



Proximité : Test KS accepté

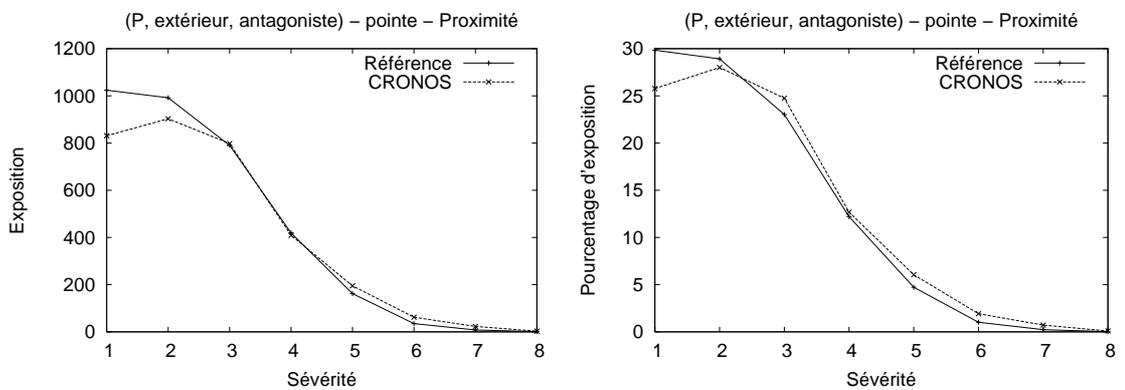
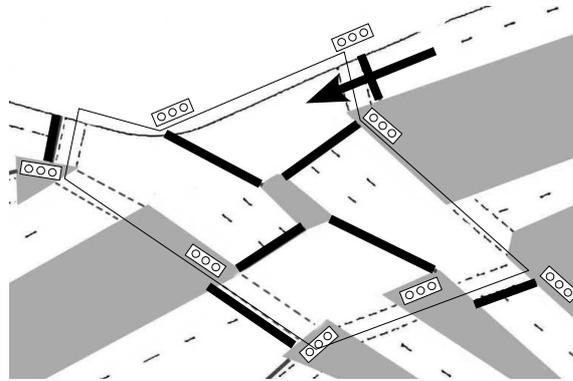
(K, centre, antagoniste en mouvement) – pointe – Vitesse



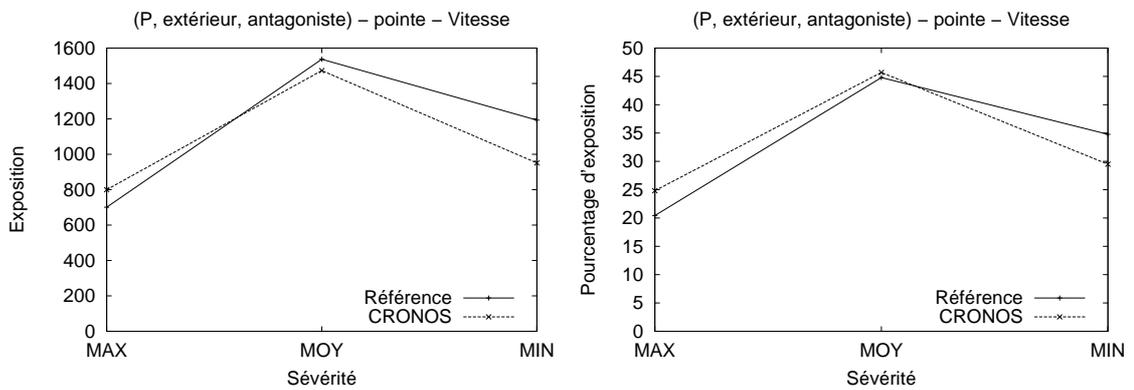
Vitesse : Test KS accepté

$$Exposition_{Référence} = 510, Exposition_{CRONOS} = 491$$

FIGURE 6.3 – Courbes d'exposition en fonction des indicateurs de sévérité, dans le contexte (K, centre, antagoniste en mouvement) en pointe, pour les 5 échantillons traités : exposition en fonction de chaque indicateur, Proximité au milieu, Vitesse en bas. Les expositions totales et tests KS pour chaque indicateur sont aussi indiqués.



Proximité : Test KS rejeté



Vitesse : Test KS rejeté

$$Exposition_{Référence} = 3431, Exposition_{CRONOS} = 3224$$

FIGURE 6.4 – Courbes d'exposition en fonction des indicateurs de sévérité, dans le contexte (P, extérieur, antagoniste) en pointe, pour les 5 échantillons traités : exposition en fonction de chaque indicateur, Proximité au milieu, Vitesse en bas avec la distribution des pourcentages d'exposition. Les expositions totales et tests KS pour chaque indicateur, sont aussi indiqués.

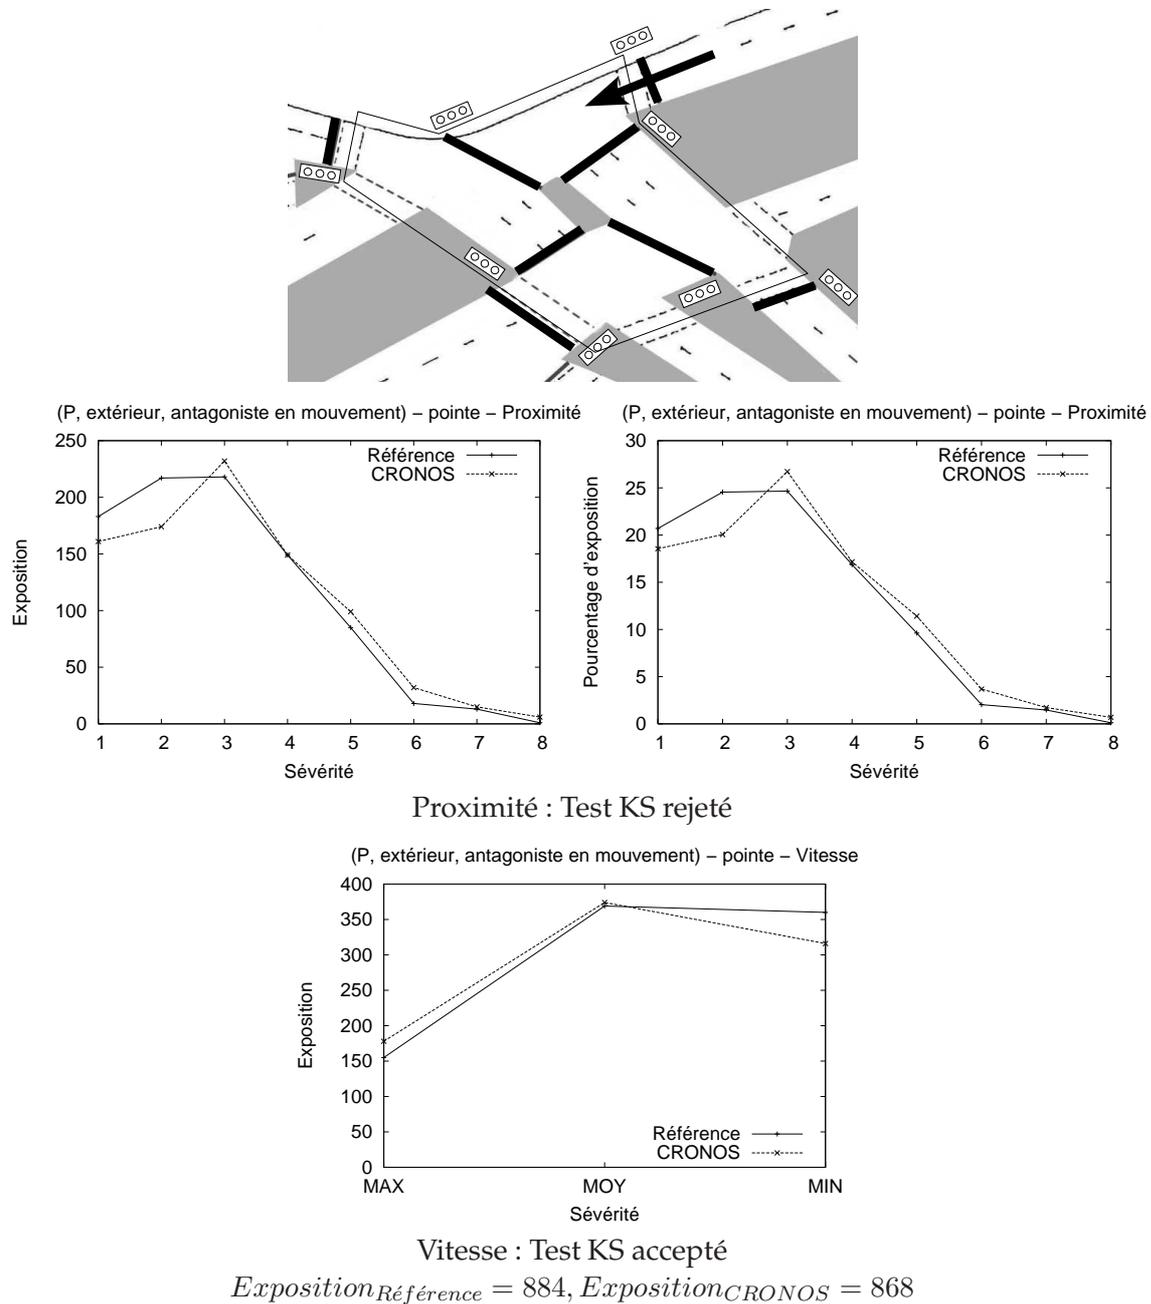
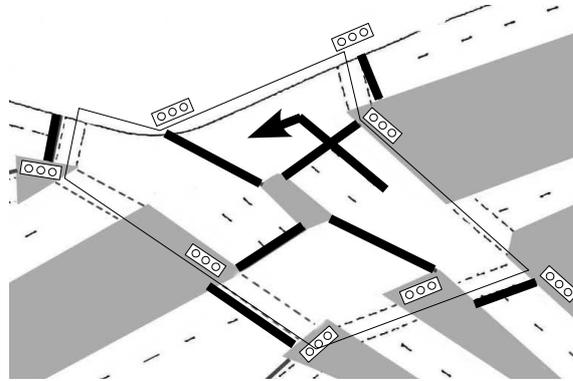
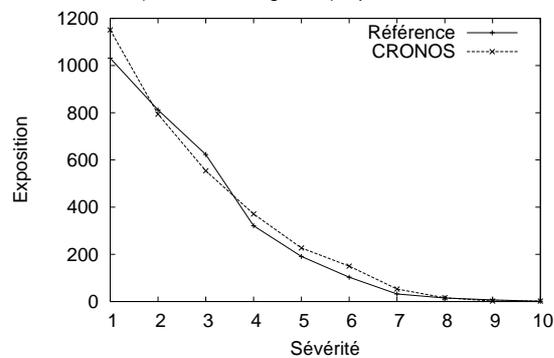


FIGURE 6.5 – Courbes d'exposition en fonction des indicateurs de sévérité, dans le contexte (P, extérieur, antagoniste en mouvement) en pointe, pour les 5 échantillons traités : exposition en fonction de chaque indicateur, Proximité au milieu, Vitesse en bas avec la distribution des pourcentages d'exposition. Les expositions totales et tests KS pour chaque indicateur sont aussi indiqués.

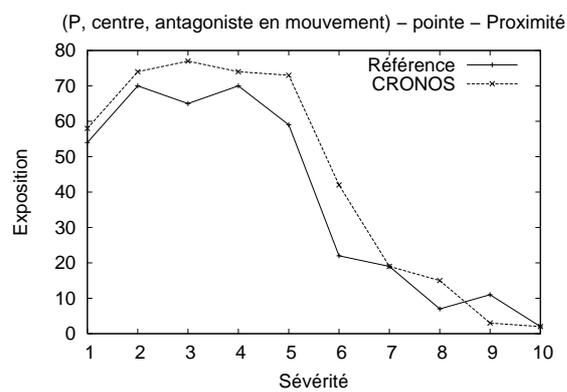


(P, centre, antagoniste) – pointe – Proximité



antagoniste : Test KS accepté

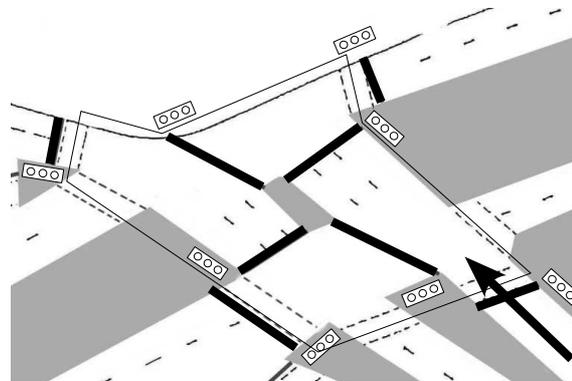
$$Exposition_{Référence} = 3136, Exposition_{CRONOS} = 3320$$



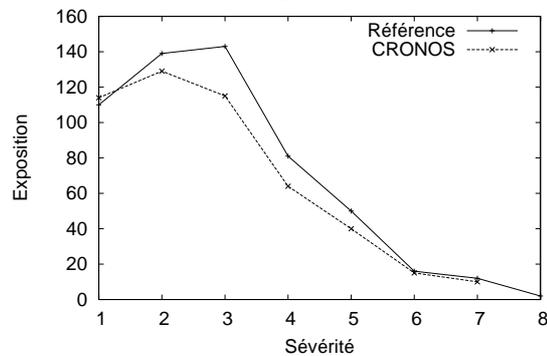
antagoniste en mouvement : Test KS accepté

$$Exposition_{Référence} = 379, Exposition_{CRONOS} = 437$$

FIGURE 6.6 – Courbes d'exposition en fonction de l'indicateur de proximité, dans le contexte (P, centre) en pointe pour les catégories antagoniste (au milieu) et antagoniste en mouvement (en bas), pour les 5 échantillons traités. Les expositions totales et tests KS sont aussi indiqués.

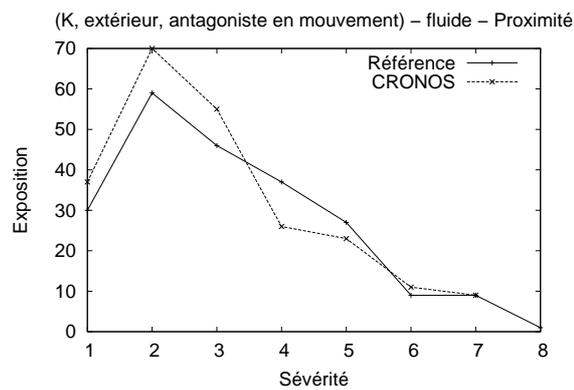


(K, extérieur, antagoniste) – fluide – Proximité



antagoniste : Test KS accepté

$$Exposition_{Référéce} = 553, Exposition_{CRONOS} = 487$$



antagoniste en mouvement : Test KS accepté

$$Exposition_{Référéce} = 218, Exposition_{CRONOS} = 231$$

FIGURE 6.7 – Courbes d'exposition en fonction de l'indicateur de proximité dans le contexte (K, extérieur) en fluide pour les catégories antagoniste (au milieu) et antagoniste en mouvement (en bas), pour les 5 échantillons traités. Les expositions totales et tests KS pour chaque indicateur sont aussi indiqués.

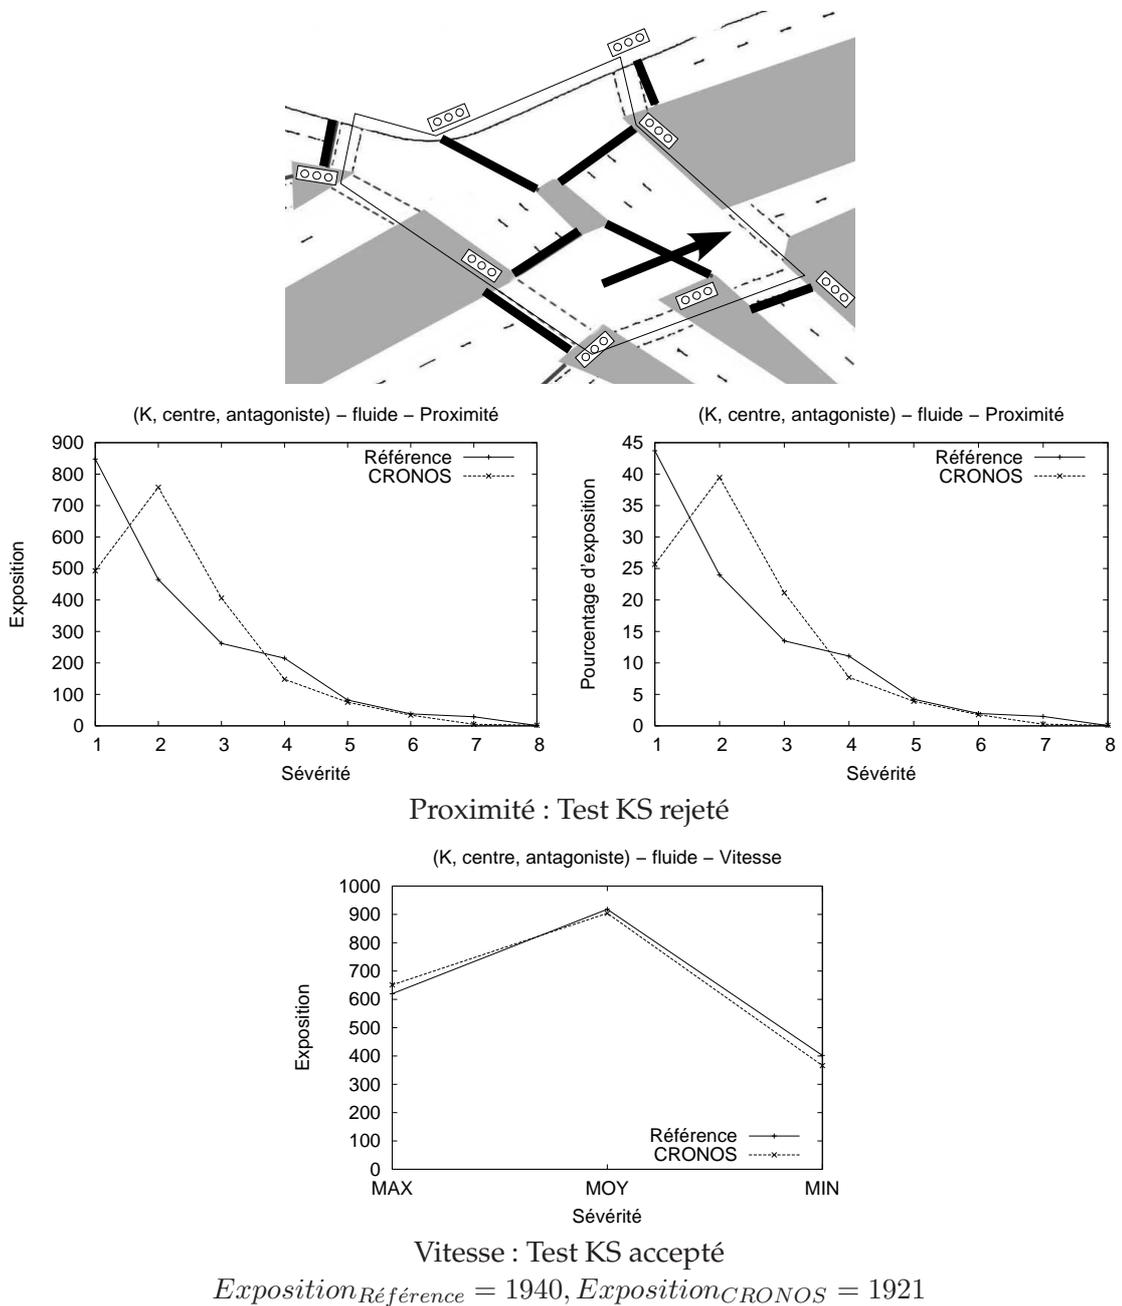
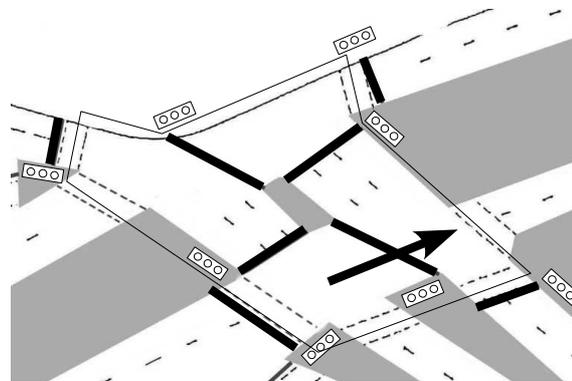
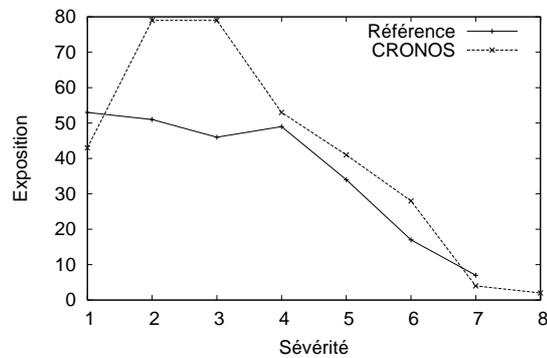


FIGURE 6.8 – Courbes d'exposition en fonction des indicateurs de sévérité, dans le contexte (K, centre, antagoniste) en fluide, pour les 5 échantillons traités : exposition en fonction de chaque indicateur, Proximité au milieu avec la distribution des pourcentages d'exposition, Vitesse en bas. Les expositions totales et tests KS pour chaque indicateur, sont aussi indiqués.

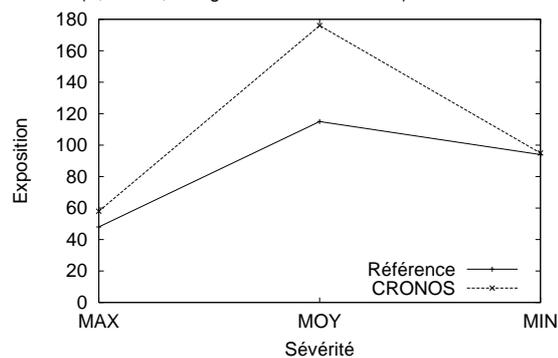


(K, centre, antagoniste en mouvement) – fluide – Proximité



Proximité : Test KS accepté

(K, centre, antagoniste en mouvement) – fluide – Vitesse



Vitesse : Test KS accepté

$$Exposition_{Référence} = 257, Exposition_{CRONOS} = 329$$

FIGURE 6.9 – Courbes d'exposition en fonction des indicateurs de sévérité, dans le contexte (K, centre, antagoniste en mouvement) en fluide, pour les 5 échantillons traités : exposition en fonction de chaque indicateur, Proximité au milieu, Vitesse en bas. Les expositions totales et tests KS pour chaque indicateur sont aussi indiqués.

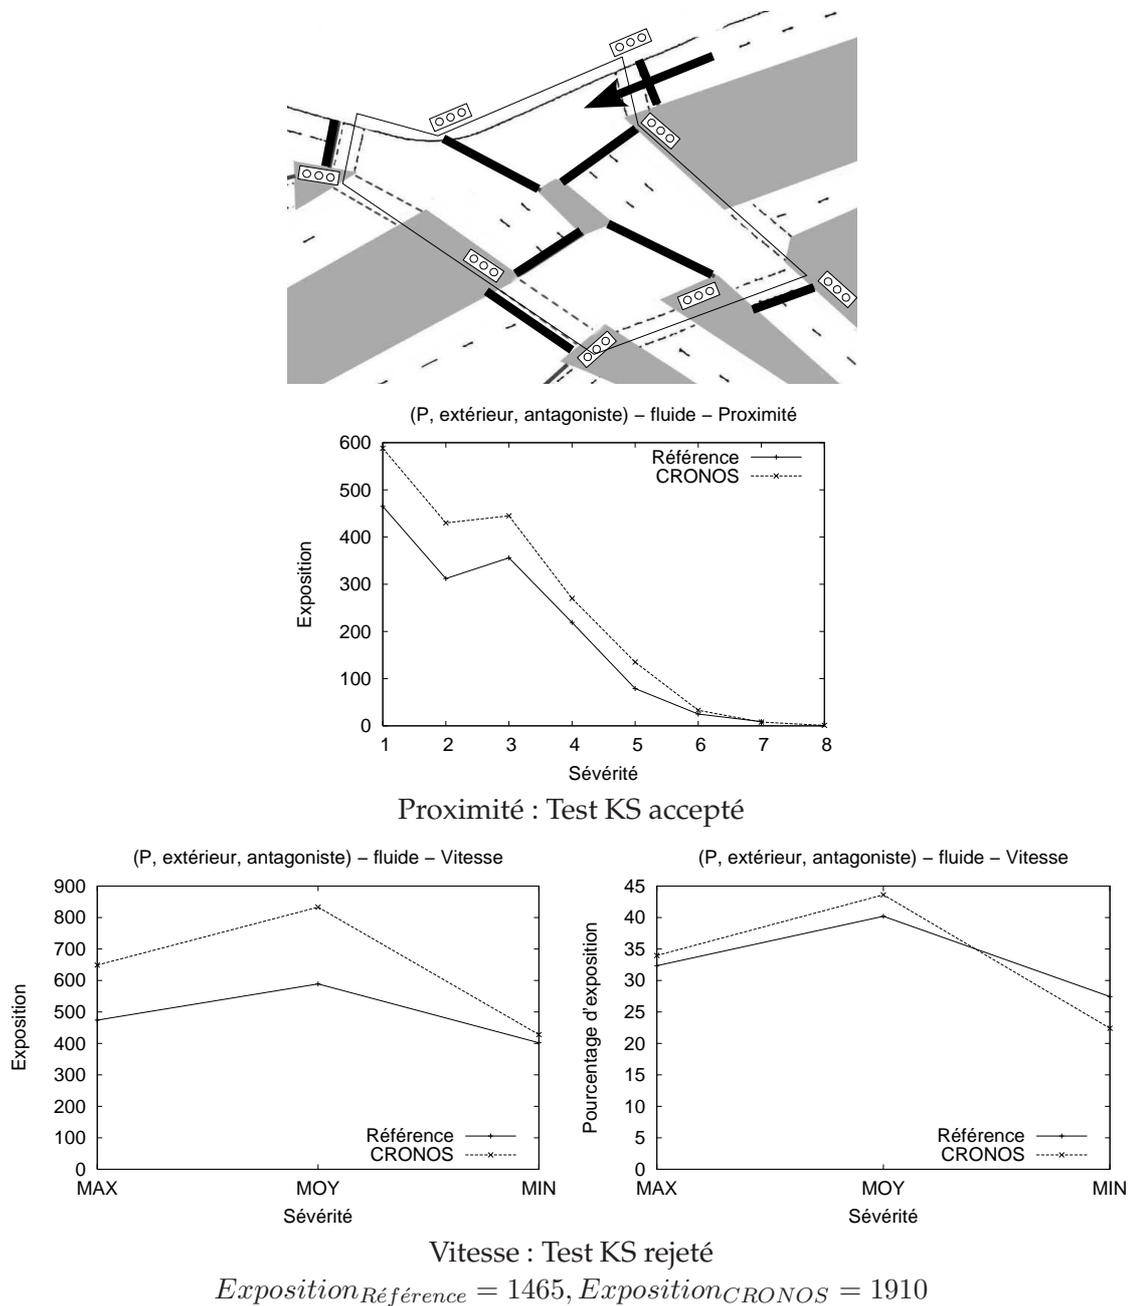
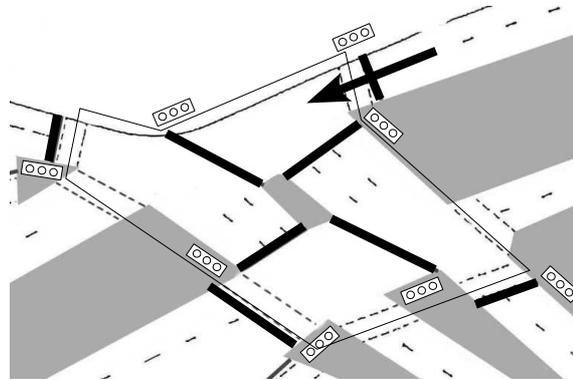
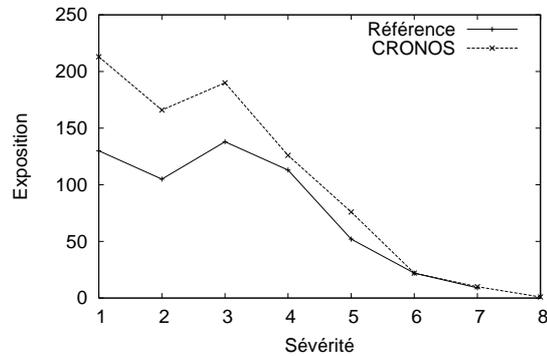


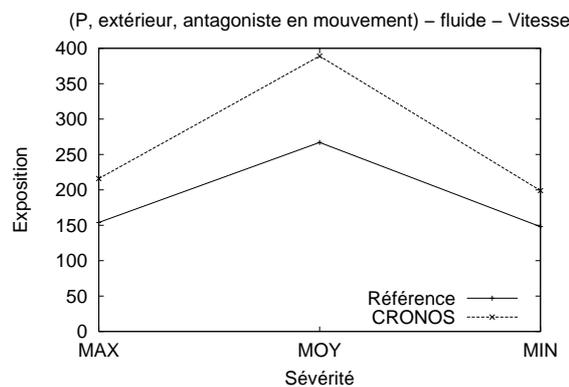
FIGURE 6.10 – Courbes d'exposition en fonction des indicateurs de sévérité, dans le contexte (P, extérieur, antagoniste) en fluide, pour les 7 échantillons traités : exposition en fonction de chaque indicateur, Proximité au milieu, Vitesse en bas avec la distribution des pourcentages d'exposition. Les expositions totales et tests KS pour chaque indicateur, sont aussi indiqués.



(P, extérieur, antagoniste en mouvement) – fluide – Proximité



Proximité : Test KS accepté



Vitesse : Test KS accepté

$$Exposition_{Référence} = 569, Exposition_{CRONOS} = 804$$

FIGURE 6.11 – Courbes d'exposition en fonction des indicateurs de sévérité, dans le contexte (P, extérieur, antagoniste en mouvement) en fluide, pour les 7 échantillons traités : exposition en fonction de chaque indicateur, Proximité au milieu, Vitesse en bas. Les expositions totales et tests KS pour chaque indicateur sont aussi indiqués.

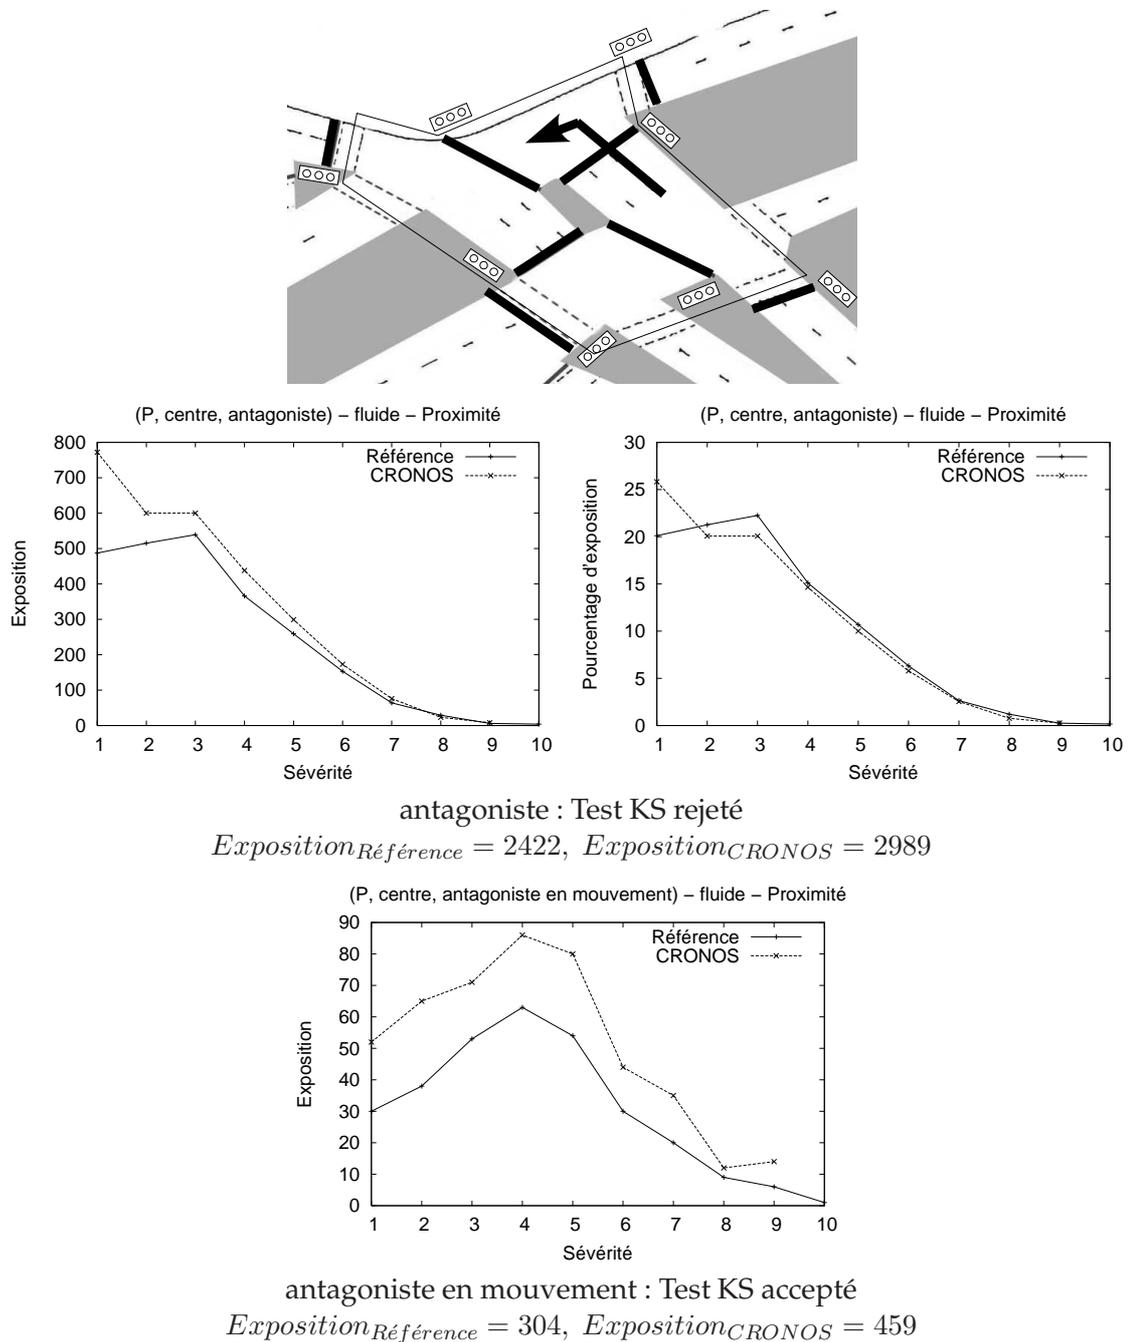


FIGURE 6.12 – Courbes d'exposition en fonction de l'indicateur de proximité dans le contexte (P, centre) en fluide pour les catégories antagoniste (au milieu, avec la distribution des pourcentages d'exposition) et antagoniste en mouvement (en bas), pour les 7 échantillons traités. Les expositions totales tests KS sont aussi indiqués.

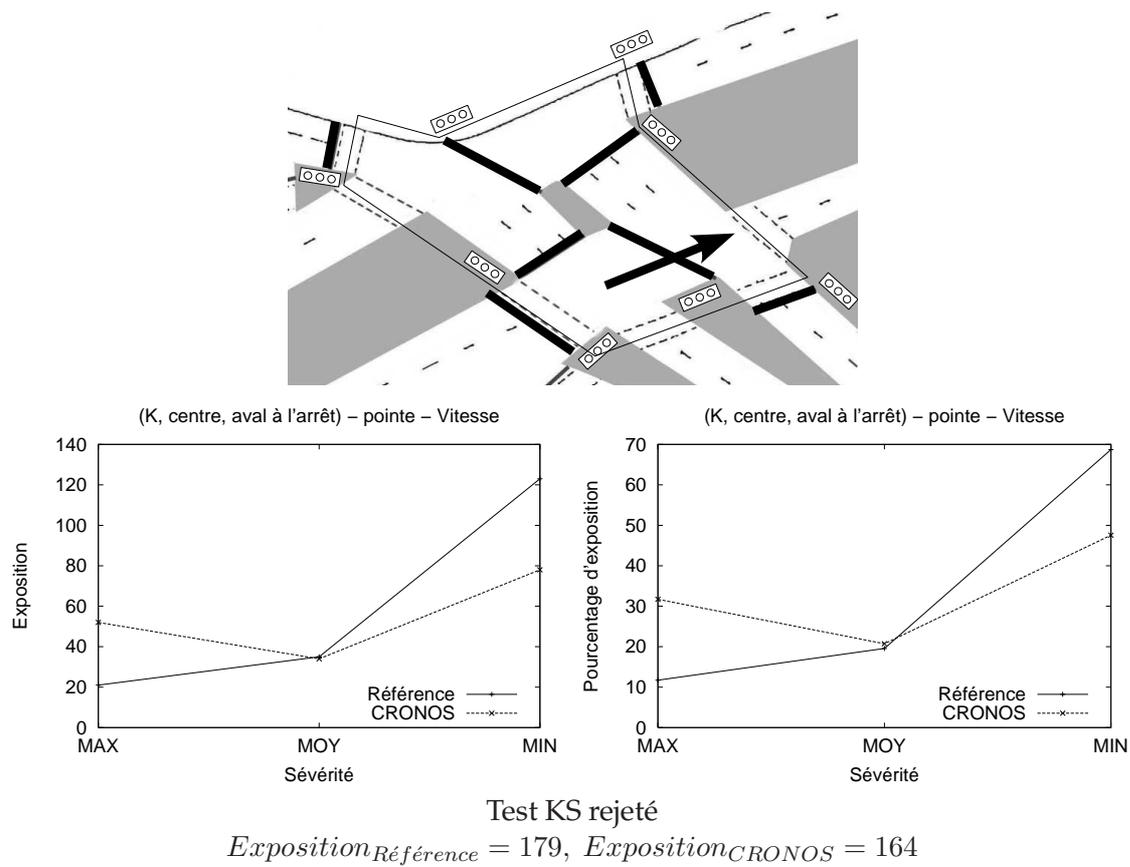


FIGURE 6.13 – Courbe d'exposition en fonction de l'indicateur de proximité, dans le contexte (K, centre) pour la catégorie aval à l'arrêt, en pointe, pour les 5 échantillons traités. Les expositions totales (leur différence relative à la stratégie de Référence est supérieure à 5%) et tests KS sont aussi indiqués.

7

Conclusion et perspectives

Bilan

Nous avons étudié dans ce travail l'influence des stratégies de régulation sur les interactions des usagers et leur sévérité.

Pour cette étude, nous avons tout d'abord proposé une *modélisation des interactions dans une intersection* pour répondre à notre problématique. Nous avons mis l'accent sur les interactions qui se déroulent dans la zone de conflit dont l'accès est contrôlé par la stratégie de régulation. Nous présentons une méthodologie pour étudier les interactions et leur sévérité. Conçu pour traiter les données de l'expérience menée dans le cadre du laboratoire CI, notre outil peut être directement utilisé dans d'autres situations, en un lieu donné, par exemple avant et après un aménagement.

Notre approche permet le *traitement semi-automatique de grandes quantités de données*, en ligne ou hors ligne, ce qui n'est pas envisageable avec la plupart des méthodes existantes. En particulier, nous nous sommes affranchis des problèmes classiques de report des événements par des observateurs, problème souvent mis en avant dans les autres méthodes de diagnostic de sécurité. Nous avons conçu un outil de diagnostic de sécurité dans une intersection, qui détecte à chaque instant les interactions et évalue leur sévérité selon deux indicateurs, un indicateur de proximité et un indicateur de vitesse. L'étude de ces interactions permet un audit du fonctionnement du carrefour.

Pour construire le module d'évaluation de la sévérité des interactions, l'indicateur de vitesse ici, nous avons mis au point une méthode originale d'*apprentissage par sélection des exemples dans un flux*. Les algorithmes développés ont été testés avec succès sur d'autres problèmes classiques ("benchmarks").

Nous avons enfin conduit notre étude à son terme en traitant une partie de la base de données de l'expérience pendant laquelle la stratégie de régulation adaptative CRONOS a été comparée à une stratégie de Référence sur un carrefour existant. Nous mettons en

évidence des *différences entre les stratégies quant à leur impact sur la sévérité des interactions*. Chaque stratégie expose plus longtemps les usagers à des interactions dans une zone de conflit (K pour la stratégie de Référence, P pour CRONOS). Selon l'indicateur de vitesse, les interactions sont proportionnellement plus sévères sous CRONOS. Nous montrons ainsi la faisabilité et l'intérêt de notre approche sur des données réelles.

Limites de notre travail

Le système de diagnostic de sécurité dans un carrefour est opérationnel au sein du laboratoire CI. De nombreux points peuvent cependant encore être améliorés.

Un certain nombre de difficultés rencontrées dans l'étude des interactions est lié à la qualité des données disponibles. La limite principale est l'impossibilité de relever les interactions les plus sévères qui découlent directement des caractéristiques des données. Sans ces interactions, il n'est pas possible de tirer des conclusions quant à la sécurité des entités étudiées, les stratégies de régulation en l'occurrence. Ces difficultés nous ont conduit à privilégier l'analyse d'interactions moins sévères, qui peuvent être qualifiées de "normales", i.e. très fréquentes et parfaitement gérées par les usagers impliqués.

Les algorithmes d'apprentissage présentés ont des résultats intéressants sur notre problème et d'autres problèmes classiques. Il est nécessaire de poursuivre leur étude pour préciser leur caractéristiques, en particulier leur sensibilité à l'algorithme de base utilisé, ici l'algorithme des classifieurs bayésiens naïfs, et aux critères de sélection.

Perspectives

Nous aurions pu aborder notre problématique de bien des façons et nous avons dû faire de nombreux choix pour aboutir à nos résultats.

A qualité de données fixée, il nous semble difficile d'améliorer significativement les performances en détection des interactions et estimation des indicateurs de sévérité. Il serait intéressant de travailler sur l'apprentissage des interactions à partir d'exemples, à l'aide d'algorithmes proches de ceux développés pour les indicateurs de sévérité. Cela pourrait en particulier permettre d'obtenir de meilleurs résultats pour les interactions de la catégorie aval à l'arrêt. Nous aimerions aussi appliquer nos méthodes dans d'autres situations, à commencer par des carrefours différents.

A plus long terme, nous pouvons nous demander ce que nous ferions si les données étaient de meilleure qualité, plus fines dans leur définition spatio-temporelle et moins bruitées, voire avec des capteurs parfaits capables de fournir les positions de tous les mobiles à chaque instant. Dans ce cas, l'approche par zone adoptée dans ce travail, trop statique, serait remplacée par une approche plus adaptée, basée sur les trajectoires des mobiles. Nous pourrions alors être capable de détecter un élément essentiel des interactions les plus sévères, la manœuvre d'évitement.

Notre travail ouvre de nouvelles pistes de recherche dans le domaine de la sécurité dans les transports, au croisement de travaux novateurs comme ceux de Å. Svensson et des méthodes de traitement semi-automatique des données, en particulier issues de l'Intelligence Artificielle. Le perfectionnement des techniques utilisées, des capteurs et des méthodes de traitement d'images sous-jacents, nous permettent d'envisager à terme une nouvelle famille d'outils de diagnostic de la sécurité en temps réel, permettant l'évaluation d'un lieu en quelques jours, alors que le temps nécessaire à des analyses comparables s'appuyant sur les accidents se compte en années. Une idée prometteuse concerne l'analyse automatique des séquences d'interactions avec leurs caractéristiques, afin de mettre en évidence des sortes de séquences "signatures" des stratégies ou toute autre entité étudiée. L'apport de techniques d'apprentissage et de la fouille de données permettront de mettre au point des outils de diagnostic plus efficaces et complets pour in fine améliorer la sécurité des usagers.



Les modules de détection des interactions

Sommaire du chapitre

A.1 Introduction à G2	159
A.2 Les principes de nos modules G2	160
A.3 L'algorithme de construction des formes dans les images	161
A.4 Les règles pour le franchissement de la ligne de feu	162

A.1 Introduction à G2

Un des objectifs de ce travail est la réalisation d'outils opérationnels de diagnostic du trafic. Nous présentons ainsi dans cette annexe et la suivante nos développements logiciels, ainsi que des détails d'algorithmes.

G2¹ est une plateforme de programmation orientée-objet dédiée à la conception de systèmes experts temps-réel. Il est possible de développer rapidement grâce à l'environnement graphique, en manipulant directement les objets et en les connectant. Le langage de programmation est un pseudo-langage naturel, avec un système de complétion à la volée. Ces éléments permettent à des non-spécialistes de modifier les applications.

S'il est possible de programmer par procédure, G2 permet au premier titre de concevoir des systèmes experts. Son moteur d'inférence raisonne sur les règles spécifiées par l'utilisateur ou le développeur chargé du transfert des connaissances. L'ensemble est conçu pour fonctionner en temps réel. Des données provenant de capteurs peuvent être modélisées par des variables temporelles munies d'historiques sur lesquels il est aussi possible de raisonner. La plateforme G2 est robuste et utilisée dans de nombreuses applications industrielles, pour la surveillance et le diagnostic d'usines, chaînes de montage, réseaux de communication ou de transports.

1. <http://www.gensym.com>

A.2 Les principes de nos modules G2

Les principales fonctions du laboratoire CI ont été développées sur cette plateforme. Nos travaux ont aussi été développés sur G2 (cf figure A.1 pour une image de l'interface), hormis les modules d'apprentissage artificiel, programmés en Java afin de bénéficier des avantages de la boîte à outils Weka (cf annexe B). Du point de vue de l'utilisateur de notre système, utilisant la plateforme G2, les modules en Java sont appelés de façon transparente grâce au module Javalink fournie avec G2.

Notre système peut traiter des données en temps réel provenant des capteurs du carrefour ou d'enregistrements. Il peut aussi traiter des données enregistrées en temps accéléré aussi vite que possible. L'existence d'interactions est détecté à chaque instant dans chaque contexte, puis les indicateurs de sévérité sont évalués dans chaque contexte. Il existe en outre deux modes principaux de validation : le premier permet de valider l'origine des mobiles entrés dans les zones de conflit, le second les indicateurs de sévérité. Il est possible de visualiser les images, et de les enregistrer, ainsi que les interactions. Les données étiquetées par un expert sont utilisées pour l'apprentissage et la validation des hypothèses construites. Les données traitées automatiquement sont enregistrées pour comparer les caractéristiques des interactions dans différents échantillons. Peuvent aussi être réglés les paramètres qui contrôlent les distances prises en compte pour la détection des passages entre zones et la présence en amont des lignes de feu.

Les modules entièrement développés sous G2 sont la détection des interactions et l'évaluation de l'indicateur de proximité. La détection consiste chaque seconde à relever les formes dans les images (cf partie A.3), puis à identifier les configurations correspondant à des interactions étudiées (cf tableau 4.2 page 63). Les indicateurs de sévérité sont évalués pour chaque contexte dans lequel au moins une interaction a été détectée. L'indicateur de proximité est directement calculé sous G2 comme un nombre de pavés entre formes. L'indicateur de vitesse est prédit par les hypothèses apprises, par l'intermédiaire de Javalink et de modules Java développés à cet effet. Les interactions et leurs caractéristiques sont affichées à chaque instant sous G2.

Nous avons construit des classes pour les principaux objets utilisés : du microscopique au macroscopique, les pavés, les formes (forme de présence à l'arrêt ou en mouvement, auxquelles une origine est attribuée), les zones fonctionnelles du carrefour et des "interfaces" entre les zones. Ces interfaces relient les zones qui communiquent. Nous nous en servons pour détecter les passages de mobile, notamment le franchissement de ligne de feu dans notre travail. Une classe représentant les interactions détectées existe aussi.

Une caractéristique très pratique offerte par G2 permet de définir des relations entre les objets, comme la relation de voisinage entre les pavés. Mises en place par exemple à l'initialisation des modules, cela permet de gagner du temps ensuite lors de l'exécution des programmes. Nous utilisons ainsi des relations entre objets pour indiquer la structure topologique du carrefour, entre les zones, les interfaces, les pavés. La relation de voisinage

entre pavés nous évite de recourir systématiquement à leurs coordonnées. G2 permet ensuite de désigner itérativement les pavés voisins d'un pavé donné.

Nous n'avons pas tiré complètement parti de l'aspect système expert afin de contrôler l'enchaînement des règles et des modules mis en oeuvre. Une seule règle au sens G2 est utilisée en temps réel pour déclencher les traitements à chaque seconde. Nous avons programmé le reste sous forme de procédures. En temps accéléré, une boucle est utilisée.

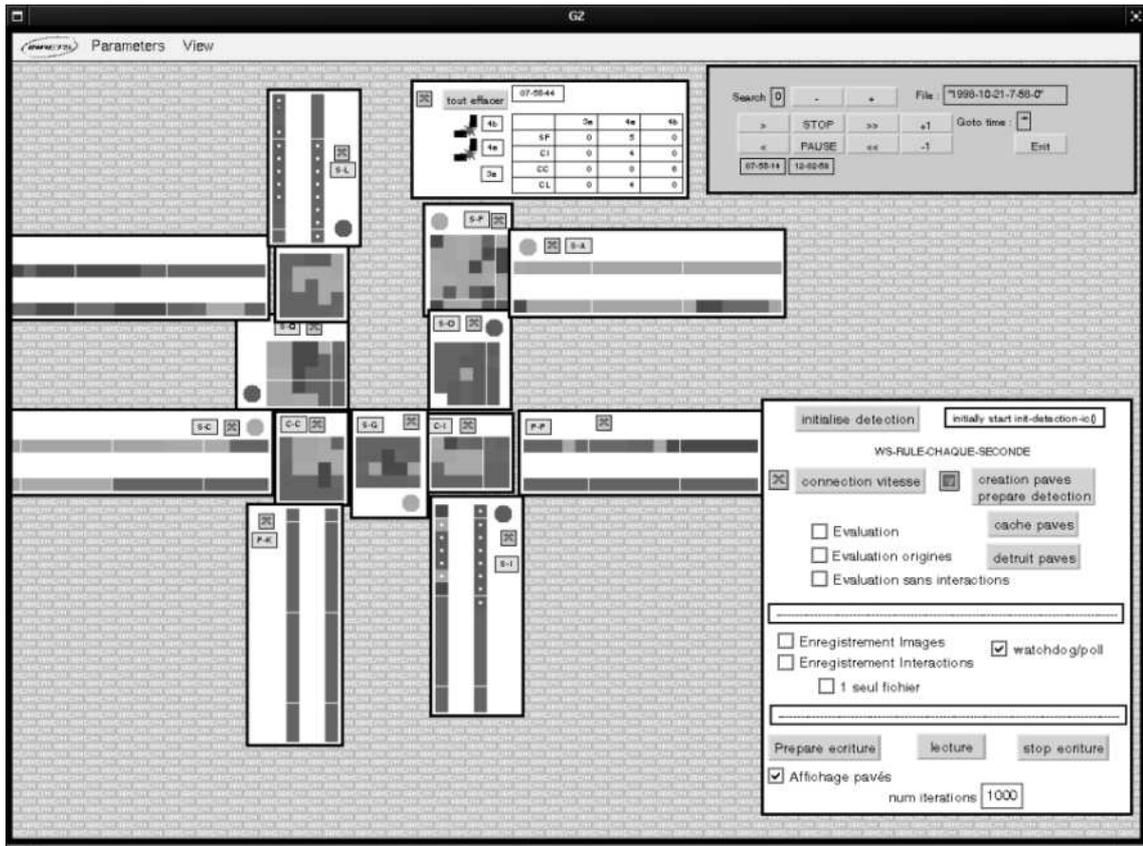


FIGURE A.1 – Espace de travail de G2, avec visualisation des données et des principales interfaces de contrôle.

Nous avons traité dans ce travail un site particulier. Il serait assez aisé de l'adapter à d'autres sites, car nous avons toujours privilégié des procédures génériques. Si les routes se croisent toujours à angle droit, ou sont considérées comme telles, il suffit d'éditer de nouveaux objets correspondant aux zones du carrefour, et de définir leurs relations topologiques. Si la structure du carrefour est plus compliquée, avec plus de deux routes qui se croisent par exemple, il faudrait revoir plus profondément nos développements, en particulier généraliser toutes les relations entre les entités du carrefour.

A.3 L'algorithme de construction des formes dans les images

Nous constituons les formes, i.e. des ensembles connexes de pavés de la façon suivante. Chaque zone est traitée indépendamment. Le voisinage utilisé est le plus réduit :

un pavé est voisin des pavés directement adjacents dans les deux dimensions, sans les diagonales (cf tableau 4.1 page 60).

1. Les ensembles connexes de pavés dans chaque état de présence sont constitués, indépendamment (avec leurs tailles minimales respectives de détection, cf tableau A.1). Tous les états sont concernés sauf le vide. Les formes de présence à l'arrêt sont terminées.
2. Les ensembles de présence en mouvement (début et fin de présence, présence en mouvement) constitués à l'étape précédente sont agrégés s'ils sont voisins.
3. Les ensembles connexes de pavés dans l'état trace de présence voisins d'une forme de présence en mouvement y sont rattachées. Les autres sont considérées comme des formes de présence en mouvement (le mobile ayant laissé les traces de présence soit n'est pas détecté, soit est détecté dans une autre zone).

Type de forme	Seuil de détection (Nombre de pavés)
Présence en mouvement (début et fin de présence, présence en mouvement)	2
Trace de présence	7
Présence en arrêt	3

TABLE A.1 – Seuils de détection des formes, i.e. tailles minimales de prise en compte des formes.

Les figures 4.3, 4.4 et 4.5 (pages 64 et 65) présentent des exemples de détection de formes, menant à la détection d'interactions. Les valeurs du tableau A.1 ont été ajustées empiriquement. Le seuil est particulièrement élevé pour les Trace de présence car cette information est très bruitée.

A.4 Les règles pour le franchissement de la ligne de feu

Nous reprenons une méthode de détection des franchissements de la ligne de feu, développée par S. Midenet dans le cadre de ses travaux sur le franchissement au rouge et la commande de feux temps réel (Midenet, 1998). Cette méthode met en jeu des règles comptant des taux de pavés dans certains états de part et d'autre d'une ligne de feu pour qualifier la situation en amont et aval de chaque ligne de feu². La méthode est générique et permet de détecter le passage d'une zone à une autre. Deux sous-ensembles de pavés des zones amont (zone de stockage) et aval (zone de conflit) de chaque ligne de feu sont délimités. Nous définissons pour un ensemble de pavés le taux $\tau_{état}$ comme le rapport du nombre de pavés dans cet état, noté $n_{état}$, sur le nombre total de pavés de l'ensemble considéré.

Pour simplifier la présentation des règles, de nouvelles valeurs des états des pavés sont introduites, composées à partir des six valeurs possibles (cf partie 3.2.3 page 41). Le

2. La classe interface a été créé à cet effet.

Etat du pavé	Information	Mouvement	Entrée	Sortie
Vide	○	○	○	○
Trace de présence	×	×	○	×
Début de présence	×	×	×	○
Fin de présence	×	×	○	×
Présence en mouvement	×	×	×	○
Présence en arrêt	×	○	○	○

TABLE A.2 – Nouvelles valeurs des états des pavés, construites à partir des 6 valeurs initiales. Une croix × indique que la valeur du pavé fait partie de la nouvelle valeur. Par exemple, la nouvelle valeur information correspond à toutes les valeurs hormis le vide.

tableau A.2 présente les nouvelles valeurs. L'état de mobilité de chaque sous-ensemble de pavés est qualifié en *Vide*, *Arrêt*, *Fin de mouvement*, *Futur mouvement* ou *Mouvement* selon les règles suivantes, présentées sous la forme des algorithmes 5 pour la zone aval et 6 pour la zone amont. Pour que ces états soient pris en compte, les zones aval et amont doivent vérifier les conditions de passage décrites dans l'algorithme 7, pour conclure à un passage entre les deux zones selon les règles de l'algorithme 8.

Enfin, une décision pour chaque zone de conflit est prise. Elle est directe si un seul franchissement de ligne de feu est détecté. Si le franchissement de plus d'une ligne de feu est détecté, la décision est prise en faveur de la zone de stockage amont pour laquelle le feu n'est pas rouge. Si les deux feux sont rouges, la décision se fait en faveur du feu passé au rouge le plus récemment. Les nombres de pavés pris en compte en aval et amont sont des paramètres réglables de notre outil.

Algorithme 5 : Règles de qualification de la zone aval d'une ligne de feu.

début

si ($\tau_{information} < 10\%$) **et** ($n_{entrée} = 0$) **alors**
l'état de la zone aval est *Vide*.

si ($\tau_{information} \geq 10\%$) **et** ($\tau_{mouvement} < 10\%$) **et** ($n_{entrée} = 0$) **alors**
l'état de la zone aval est *Arrêt*.

si l'état de la zone aval n'est ni *Vide*, ni *Arrêt* **alors**

si $n_{mouvement} = n_{fin\ de\ présence}$ **alors**
l'état de la zone aval est *Fin de mouvement*.

sinon
l'état de la zone aval est *Mouvement*.

fin

Algorithme 6 : Règles de qualification de la zone amont d'une ligne de feu.

début

si ($\tau_{information} < 10\%$) *et* ($n_{sortie} = 0$) **alors**
 l'état de la zone amont est *Vide*.

si ($\tau_{information} \geq 10\%$) *et* ($\tau_{mouvement} < 10\%$) *et* ($n_{sortie} = 0$) **alors**
 l'état de la zone amont est *Arrêt*.

si l'état de la zone amont n'est ni *Vide*, ni *Arrêt* **alors**
si $n_{mouvement} = n_{début\ de\ présence}$ **alors**
 l'état de la zone amont est *Futur mouvement*.

sinon
 l'état de la zone amont est *Mouvement*.

fin

Algorithme 7 : Règles pour que les zones aval et amont vérifient les conditions de passage (\neg *Mouvement* désigne n'importe quel état de la zone hormis *Mouvement*.).

début

si l'état de la zone amont est *Mouvement* **alors**
 la condition de la zone amont est vérifiée.

si l'état de la zone aval passe de *Mouvement* à \neg *Mouvement* **alors**
 la condition de la zone amont n'est pas vérifiée.

si l'état de la zone aval est *Mouvement* *et* la condition de la zone amont est vérifiée
alors
 la condition de la zone aval est vérifiée.

sinon
 la condition de la zone aval n'est pas vérifiée.

fin

Algorithme 8 : Règles pour conclure au passage entre deux zones.

début

si les conditions des zones aval et amont sont vérifiées **alors**
si (l'état de la zone aval est *Mouvement*) *et* ($\frac{n_{mouvement}}{n_{information}} \geq 50\%$) **alors**
 Conclure à un passage entre les deux zones

fin

*Found only on the islands of New Zealand,
the weka is a flightless bird with an inquisitive nature.*

WEKA's website

B

Les modules d'apprentissage

Sommaire du chapitre

B.1	Introduction	165
B.2	Les modules programmés	166
B.2.1	Les données	166
B.2.2	L'apprentissage	167
B.2.3	Les utilitaires	170
B.3	Temps de calcul des algorithmes d'apprentissage	171

B.1 Introduction

Nous décrivons dans cette partie les développements logiciels liés à notre travail sur les algorithmes d'apprentissage d'indicateurs de sévérité. Nous avons essayé de rendre nos programmes très modulaires afin de tester facilement différents algorithmes, et de pouvoir ré-utiliser notre travail.

Nous avons choisi la plateforme Java et la boîte à outils Weka du Département Informatique de l'Université de Waikato pour développer nos algorithmes d'apprentissage artificiel. Java¹ est un langage pratique et aux performances correctes, bien que souvent décriées. Un atout important auquel nous tenons est son aspect multi-plateforme. Le code compilé en bytecode est interprété par une machine virtuelle, ce qui explique la lenteur des applications Java comparées à du code natif. Sun fournit des machines virtuelles pour de nombreux systèmes d'exploitation (UNIX, Windows, Linux, MacOS).

Weka est une boîte à outils bien connue disponible sur internet². Elle propose un ensemble d'algorithmes d'apprentissage artificiel pour des tâches de fouille de données

1. <http://java.sun.com>

2. <http://www.cs.waikato.ac.nz/ml/weka/index.html>

("Data Mining") (Witten et Frank, 2000). Sont disponibles des outils pour le pré-traitement des données, la classification, supervisée ou non, la régression, l'apprentissage de règles et la visualisation. Weka est programmé en Java, donc dispose des avantages sus-cités, et est distribué gratuitement sous la license GNU GPL. Weka est mise à jour régulièrement, est doté d'une bonne documentation, et d'une communauté vivante d'utilisateurs³. Weka peut être utilisé principalement de deux façons. Les algorithmes peuvent être directement appliqués à des ensembles de données, par une interface graphique ou en ligne de commande. Les classes du paquetage Weka peuvent être directement utilisées dans d'autres programmes Java.

Nous faisons communiquer les outils de la plateforme CI, développés sous G2, avec les outils développés en Java à l'aide du module Javalink distribué avec G2. Les algorithmes développés en Java, en particulier ceux d'apprentissage qui font appel à Weka, peuvent être appelés directement de G2 de façon transparente pour l'utilisateur.

Il est ainsi aisé de développer de nouvelles méthodes d'apprentissage. Il est particulièrement appréciable de ne pas avoir besoin de programmer tous les algorithmes d'apprentissage qu'il semble intéressant de tester sur un problème, avec toutes les possibilités d'erreurs inhérentes. Cependant certains choix d'implémentations en Weka sont contraignants et difficiles à contourner pour des cadres d'apprentissages moins classiques. Un exemple est l'impossibilité d'introduire simplement des exemples munis de multiples étiquettes ou de degrés d'appartenance.

B.2 Les modules programmés

Nous avons organisé les classes en quatre paquetages, décrits dans la suite selon leur finalité : `cinico` pour les données (hors apprentissage), `learning` pour l'apprentissage, `utils` et `viewer` pour les utilitaires finaux.

B.2.1 Les données

Les classes qui représentent et traitent les données, i.e. les images et les interactions, sont rassemblées dans le paquetage `cinico`. Nous avons créé une classe `Interaction` pour représenter les attributs des interactions. Les images n'ont pas de classe propre et sont traitées temporairement sous la forme de tableaux d'entiers avant d'être converties au format ARFF⁴ utilisé par Weka. Un objet de la classe `Interaction` possède un attribut qui contient l'image à l'origine de sa détection.

La plupart des méthodes génériques utilisées, ainsi que des informations sur les données relatives au site expérimental, sont contenues dans la classe `CiNico`, respectivement

3. Les archives de la liste de diffusion en témoignent.
<https://list.scms.waikato.ac.nz/pipermail/wekalist>

4. Un fichier ARFF ("Attribute-Relation File Format") est un fichier texte ASCII qui décrit une liste d'exemples partageant un ensemble d'attributs. Le format a été développé spécifiquement pour le projet Weka.

<http://www.cs.waikato.ac.nz/~ml/weka/arff.html>

comme des attributs et des méthodes de classe (statiques). La majorité de ces attributs sont des tableaux qui contiennent la description de la topologie du site, en particulier des zones et des contextes (lieu, origine, catégorie) étudiés. Pour des raisons d'efficacité, tous les éléments de contexte sont stockés sous forme de nombres qui sont des indices dans les tableaux des valeurs possibles prises par ces éléments de contexte. Les méthodes de CiNico permettent de lire et écrire les fichiers des images du carrefour et des interactions (méthodes `readImage` et `readInteraction`), de convertir les données (interactions, images, dates...) entre les différents formats utilisés... Les fichiers d'interaction contiennent tous les contextes dans lesquels il y a interaction, à un instant donné, ou sur un intervalle de temps donné pour limiter les temps d'accès au fichier lors de l'analyse des résultats. Notre format permet de traiter un nombre indéterminé d'indicateurs de sévérité.

Nous avons aussi développé des classes qui permettent de manipuler des ensembles d'interactions. Elles héritent de la classe abstraite `Base`. Deux types d'ensembles ont été développés, correspondant à deux étapes dans notre travail. Nous avons d'abord considéré plusieurs interactions par contexte (classe `BaseInteraction`). Devant le manque de fiabilité de ces résultats, nous avons simplifié notre approche pour ne traiter que l'existence d'interactions par contexte, et la qualification de ces instants par les valeurs les plus sévères des indicateurs (classe `BaseInstant`). Ces classes nous permettent en particulier d'étudier la distribution de l'exposition en fonction des indicateurs de sévérité pour comparer les stratégies de régulation, à l'aide de la classe `Distribution` du package `utils`.

Les classes du package `cinico` ne sont jamais exécutées telles quelles, mais sont instanciées ou leur méthodes statiques appelées dans les classes plus simples du package `utils`.

B.2.2 L'apprentissage

Le package `learning` comprend toutes les classes utilisant des classes de la boîte à outil Weka, pour circonscrire la dépendance de nos travaux à Weka. A la différence de `cinico`, ce package contient donc des classes exécutables, celles qui nous ont permis de tester nos algorithmes d'apprentissage, pour ensuite apprendre l'indicateur de vitesse des interactions détectées et utiliser les hypothèses apprises pour comparer différents échantillons, en particulier l'influence des stratégies de régulation des feux. Ce sont `BenchClassification` et `StreamClassification`, respectivement pour les ensembles de référence et nos données de trafic.

La plupart des méthodes génériques utilisées, ainsi que des informations spécifiques au problème d'apprentissage, sont contenues dans la classe `Learning`, en tant qu'attributs et méthodes de classe. S'y trouvent en particulier les méthodes de formatage des exemples au format ARFF.

Nous avons développé nos algorithmes d'apprentissage en plusieurs itérations au fur et à mesure de nos recherches. Nous avons privilégié leur modularité pour simplifier la programmation et la composition des méthodes comparées, par exemple entre l'algorithme de sélection d'exemples dans un flux et l'algorithme de base.

Nous avons programmé en premier dans la classe abstraite `SActiveLearning` l'algorithme de sélection d'exemples dans un flux (cf algorithme 1, page 97), de façon générique par rapport à l'algorithme de base et aux critères de sélection et d'arrêt. Des classes abstraites ont été créées pour ces deux critères, respectivement `SelectionCriterion` et `StoppingCriterion`. Les critères utilisés dans les algorithmes héritent de ces classes, en implémentant respectivement les méthodes `select` et `continue`, dont les valeurs de retour indiquent respectivement s'il faut sélectionner l'exemple passé en argument et continuer l'apprentissage. Par défaut, le constructeur de `SActiveLearning` instancie des versions simples qui respectivement acceptent tous les exemples et n'arrêtent pas l'apprentissage, programmées sous forme de classes anonymes.

Nous avons programmé plusieurs critères de sélection des exemples.

- la classe `MisclassifiedSelectionCriterion` pour le critère MC de sélection des données mal-classées par l'hypothèse courante (cf page 101),
- la classe `QBCSelectionCriterion` pour le critère QBC de sélection d'exemples de l'algorithme de requête par comité (cf page 99), qui fonctionne donc avec la classe `VoteOrderSAL` décrite plus loin,
- la classe `UncertaintySelectionCriterion` pour le critère CSeuil basé sur la confiance et un seuil (cf page 99),
- la classe `WeightedRandomSelectionCriterion` pour le critère CProba basé sur la confiance et un tirage aléatoire selon cette confiance (cf page 99).

`SActiveLearning` implémente l'interface de Weka `UpdateableClassifier` de Weka pour les algorithmes incrémentaux, ce qui implique que la classe doit définir une méthode `updateClassifier` qui permet de mettre à jour l'hypothèse sur un nouvel exemple. Nous supposons que l'algorithme de base est aussi incrémental. Il implémente aussi notre interface `InstancesSelector` pour les algorithmes qui sélectionnent des exemples, ce qui implique qu'ils instancient la méthode `numChosenInstances` qui retourne le nombre d'exemples sélectionnés par l'algorithme.

La classe non-abstraite la plus simple qui hérite de `SActiveLearning` est `SActiveLearningSimple`. Elle met en oeuvre avec la classe `MisclassifiedSelectionCriterion` l'algorithme MC (la classe de l'algorithme incrémental des classifieurs bayésiens naïfs disponible dans Weka est `NaiveBayesUpdateable`). Nous avons aussi travaillé sur des algorithmes faisant intervenir un vote des dernières hypothèses construites au cours du processus d'apprentissage (cf algorithme 3 page 106) réalisés dans les classes `SActiveLearningVote` (classe abstraite) et `SActiveLearningVoteLast`. Le diagramme de ces classes est présenté dans la figure B.1.

- l'algorithme incrémental est mis en oeuvre dans la classe `VoteOrderSAL`, qui implémente donc `UpdateableClassifier`. Avec la classe `MisclassifiedSelectionCriterion`, cette classe correspond à `Vote MC`.
- l'algorithme non-incrémental est mis en oeuvre dans la classe `VoteRandomOrderSAL`. Avec la classe `MisclassifiedSelectionCriterion`, cette classe correspond à `Vote AleaMC`.

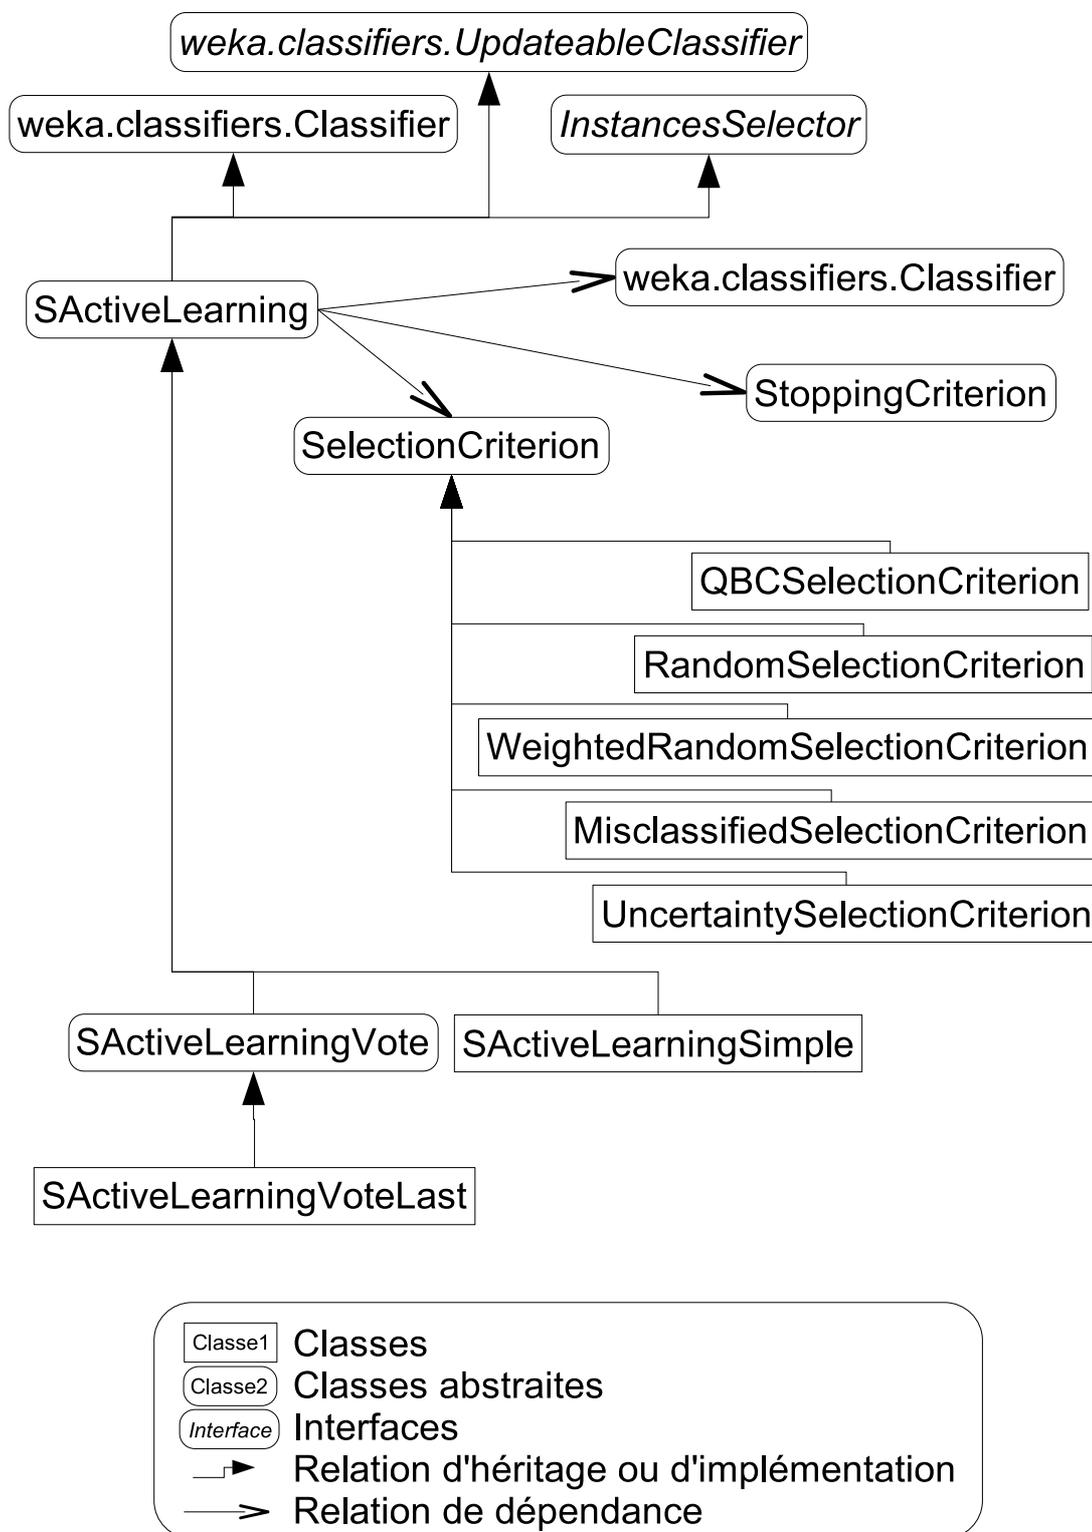


FIGURE B.1 – Diagramme simplifié des classes pour les algorithmes d’apprentissage par sélection de données dans un flux. Les classes de Weka sont indiquées avec leur nom complet (par exemple weka.classifiers.Classifier).

Les hypothèses qui composent ces votes ne sont pas apprises sur le même nombre d'exemples. Leurs méthodes `numChosenInstances` retournent alors le nombre moyen d'exemples sélectionnés. Le diagramme de ces classes est présenté dans la figure B.2.

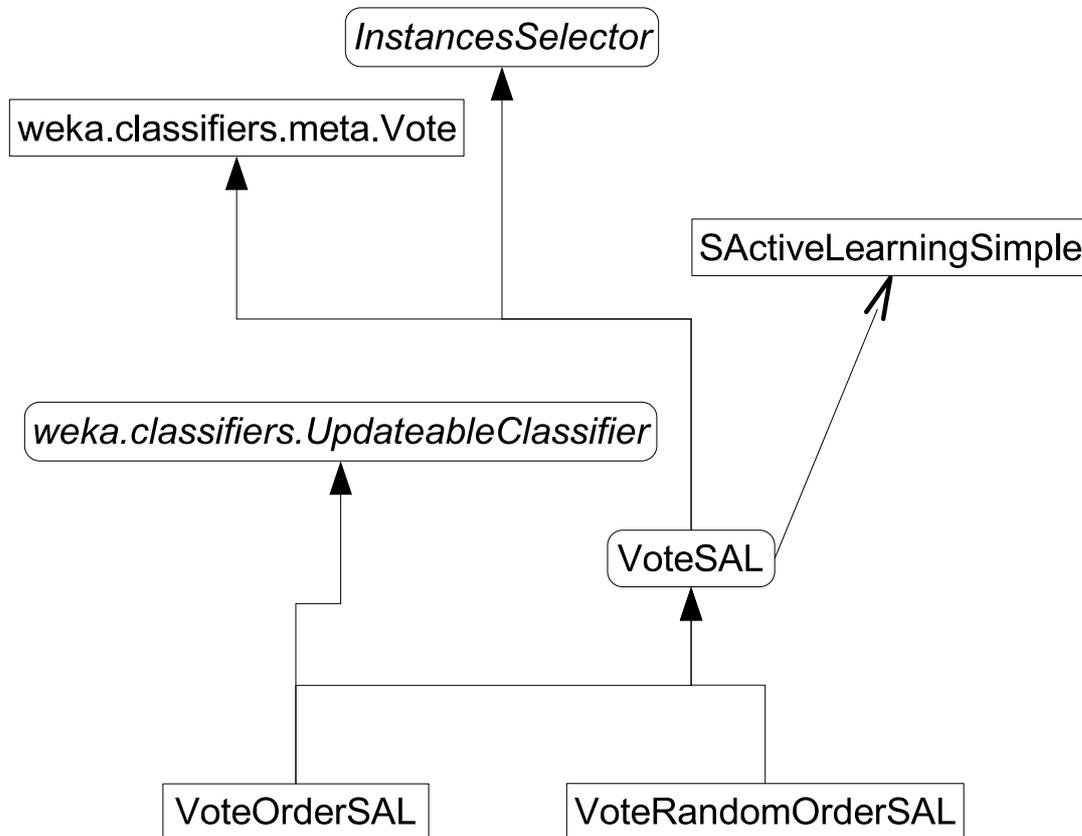


FIGURE B.2 – Diagramme simplifié des classes pour les algorithmes d'apprentissage par sélection de données dans un flux faisant intervenir un vote (comme Vote MC et Vote AleaMC). Les classes de Weka sont indiquées avec leur nom complet (par exemple `weka.classifiers.Classifier`).

Nous avons l'intention de soumettre ces développements à l'équipe qui maintient Weka pour l'enrichir de fonctionnalités d'apprentissage actif incrémental.

B.2.3 Les utilitaires

Les classes du paquetage `utils` sont plus simples que celles des autres paquetages. Ce sont des exécutables qui ne contiennent pour la plupart qu'une méthode statique `main`. Nous reprenons l'interface en ligne de commande de Weka, sous la forme classique `-caractère option`. Ces exécutables font appel aux classes des paquetages `cinico` et `learning` et permettent d'effectuer diverses opérations : analyse des ensembles de données (ensemble des fichiers d'interactions contenus dans un répertoire) ou de plusieurs échantillons, conversion d'ensembles de fichiers d'interactions contenus dans un répertoire au format Weka, calcul de moyennes et d'écart-types pour les fichiers de performances des algorithmes d'apprentissage, calcul des performances d'une hypothèse sérialisée dans

un fichier sur un ensemble d'exemples étiquetés... Les comparaisons des échantillons, de l'exposition et de leur distribution selon les indicateurs de sévérité (à l'aide de la classe Distribution) sont effectuées dans une classe qui lit les fichiers d'interactions et génère des fichiers au format gnuplot⁵ permettant de tracer les courbes d'exposition.

Après un programme pour convertir les données du carrefour en fichiers images, nous avons réalisé une interface graphique pour visualiser directement les données, accompagnées de leurs fichiers d'interactions (cf figure B.3). Les classes de cet outil sont regroupées dans le paquetage viewer. Elles font appel aux méthodes de lecture des données de la classe CiNico. Cet outil affiche les données dans leur ordre chronologique, mais aussi dans l'ordre de la valeur de l'indicateur de sévérité des instants d'interaction, pour des essais sur l'apprentissage d'un ordre sur les données.

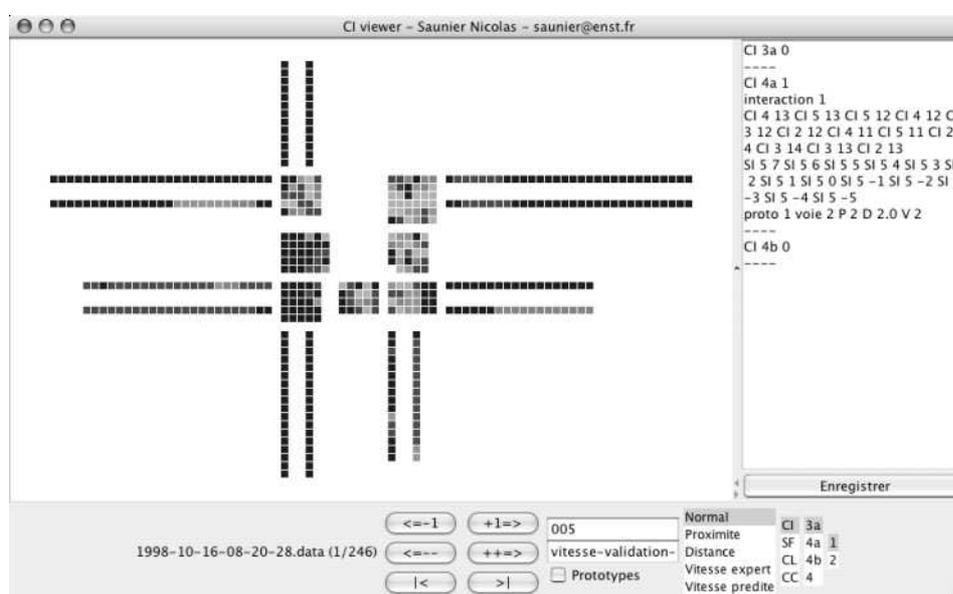


FIGURE B.3 – Interface de l'outil de visualisation des données.

B.3 Temps de calcul des algorithmes d'apprentissage

Malgré les difficultés inhérentes à ces résultats, leur dépendance à l'implémentation des algorithmes et à la plateforme utilisée, nous présentons des temps de calcul à titre indicatif pour donner une idée du coût des algorithmes comparés dans le chapitre 5 (cf tableaux B.1). Il s'agit uniquement des problèmes classiques.

Nous pouvons faire quelques remarques. Conformément à ce que nous pouvons attendre, nous observons que le temps de calcul nécessaire à l'apprentissage de N_h hypothèses est bien de l'ordre du produit de N_h par le temps de calcul nécessaire à l'apprentissage d'une hypothèse (ici $N_h = 10$). C'est visible pour Cseuil et Vote Cseuil, CProba et Vote CProba, MC et Vote MC, ainsi que NB et Bagging. Nous notons que les critères de sélection des données n'ont pas tous le même coût : MC a le plus faible coût, puis

5. <http://www.gnuplot.info>

Problème	Vote MC	MC	QBC	CSeuil	CProba	Vote CSeuil	Vote CProba
mushroom	13382	1336	2930	2517	2561	24616	26320
	1405	238	1449	190	187	1406	1461
soybean	10489	1019	3367	2005	1993	20550	20459
	1640	118	1660	119	120	1657	1634
vote	486	48	130	94	93	938	926
	53	8	53	7	7	53	53
tic-tac-toe	760	77	259	155	139	1574	1415
	78	11	76	12	11	75	76
iris disc	83	9	25	15	16	147	155
	8	2	9	1	1	9	8
car	1560	151	469	295	293	3016	2988
	165	24	176	24	23	167	162
cmc disc	1973	166	524	320	309	3462	3233
	173	23	177	23	24	157	167
connect-4	304342	30441	76089	58740	55908	605558	574333
	31539	3853	32179	3608	3728	32414	31922
derma disc	2178	217	672	421	417	4261	4216
	270	26	296	26	26	271	273
promoters	466	47	202	85	81	849	807
	50	5	54	5	5	51	51
audiology	10542	914	3572	1748	1735	18475	18296
	1580	104	1719	104	116	1520	1510

Problème	Vote MC	MC	Bagging	NB	Vote AleaMC	AdaBoost	SVM
mushroom	13382	1336	7397	795	14952	37481	/
	1405	238	1399	221	1509	1420	/
soybean	10489	1019	1180	90	10455	21541	/
	1640	118	1634	119	1638	1593	/
vote	486	48	308	26	510	1382	5880
	53	8	51	7	53	50	50
tic-tac-toe	760	77	487	41	823	2132	/
	78	11	72	11	90	73	/
iris disc	83	9	59	4	91	251	5175
	8	2	8	2	8	7	18
car	1560	151	726	56	1684	4044	/
	165	24	158	25	169	148	/
cmc disc	1973	166	791	64	2033	1655	/
	173	23	178	32	172	50	/
connect-4	304342	30441	110446	11116	316955	576967	/
	31539	3853	31006	3638	32584	24111	/
derma disc	2178	217	554	49	2188	4950	38599
	270	26	267	26	270	272	1887
promoters	466	47	254	24	469	890	2978
	50	5	49	5	50	39	157
audiology	10542	914	1824	81	10034	21164	665649
	1580	104	1568	103	1583	1631	3444

TABLE B.1 – Résultats sur les 11 problèmes classiques, temps de calcul indicatifs en secondes sur les ensembles d'apprentissage et de test (10 validations croisées en 10 fois) (processeur PPC G4 800 MHz, 640 Mo). Les performances de SVM ne sont pas toujours disponibles en raison de leur coût computationnel.

viennent CSeuil et CProba. Le critère QBC est peu coûteux puisqu'il faut le comparer aux algorithmes faisant intervenir un vote, i.e. Vote Cseuil, Vote CProba et Vote MC.

Il faut noter que le coût nécessaire à l'apprentissage de Vote AleaMC est proche, mais un peu supérieur à Vote MC. Vote AleaMC est nettement moins coûteux en apprentissage qu'AdaBoost (et que SVM), et ses performances sont souvent meilleurs ou équivalentes. Il est cependant difficile de tirer des conclusions tant la dépendance aux choix d'implémentations est importante.



Valorisation des compétences

Sommaire du chapitre

C.1 Cadre général et enjeux de ma thèse	175
C.2 Contexte	176
C.3 Conduite du projet	178
C.3.1 Gestion du temps	178
C.3.2 Gestion des relations extérieures	178
C.3.3 Budget et financement	179
C.4 Compétences développées dans le cadre de mon projet	180
C.5 Conclusion	181

Le programme "Valorisation des compétences - un nouveau chapitre de la thèse", initié par l'Association Bernard Grégory¹, aide les doctorants en fin de thèse à faire le bilan de leurs compétences et à les valoriser. Ce chapitre a été réalisé sous la direction du "mentor" Joël de Nervaux.

C.1 Cadre général et enjeux de ma thèse

Ma thèse d'intelligence artificielle s'inscrit dans le cadre de la régulation des carrefours à feux et du développement d'outils intégrés de gestion du trafic, alimentés par capteurs vidéos. Nous travaillons avec un dispositif expérimental d'observation automatique d'un carrefour réel, sur les données duquel nous nous sommes appuyés. Le problème consiste à analyser des données dynamiques d'occupation du carrefour, de définir des indicateurs pertinents qui caractérisent les dysfonctionnements opérationnels ou sécuritaires, et de développer un système automatique de détection. Les techniques employées font appel aux systèmes à base de règles et à l'apprentissage automatique pour la reconnaissance des formes. Nous utilisons pour cela des connaissances disponibles en acciden-

1. <http://www.abg.asso.fr>

tologie, notamment la technique de description des conflits de trafic traditionnellement utilisée de manière manuelle pour le diagnostic sécuritaire des carrefours.

D'un point de vue technique, ma thèse a un objectif très concret et précis dans le domaine de la gestion des carrefours à feux et les outils de diagnostic de sécurité routière. Le potentiel d'un tel outil est très important. Il n'existe aujourd'hui aucun outil de diagnostic automatique de la sécurité routière. La plupart des études de sécurité se base sur les relevés d'accidents. Outre des problèmes théoriques, l'usage des accidents pour le diagnostic de sécurité pose le problème de la durée des périodes nécessaires pour disposer d'assez de données. Un outil automatique relevant des événements plus fréquents dans le trafic que les accidents réduirait les périodes d'évaluation de la sécurité du trafic, et pourrait être aussi utilisés pour le diagnostic temps réel.

Le contexte économique français est peu propice au développement de ce genre d'outils, à la différence de l'étranger et du monde anglo-saxon en particulier. Les aménagements des carrefours urbains sont à la charge des municipalités en France, et celles-ci ne disposent pas des budgets nécessaires pour investir dans ces outils. Au contraire, les carrefours nord-américains sont déjà fortement équipés de capteurs vidéo pouvant fournir les données nécessaires à notre outil.

La sécurité routière est un problème de société mondial. Selon les projections de l'Organisation Mondiale de la Santé, la sécurité routière sera une des trois principales causes de décès dans les pays en développement d'ici à 2020. En France, après un effort historique, le nombre annuel de morts sur les routes a amorcé une spectaculaire baisse entre les années 2002 et 2003, et la tendance se confirme en 2004. Il est nécessaire de développer de nouvelles méthodes pour s'approcher de la "Vision Zéro" suédoise.

Les résultats attendus concernent de nouvelles approches de la sécurité dans les carrefours, et des outils de diagnostic automatique de la sécurité et du comportement des usagers, appliqués à une comparaison de différentes stratégies de gestion des feux sur la sécurité. Ceci nous a conduit à des développements originaux dans le domaine de l'apprentissage automatique permettant la sélection de données dans des flux pour améliorer la qualité de l'apprentissage du système.

C.2 Contexte

J'ai effectué mon travail de thèse au sein de deux laboratoires. Le premier d'entre eux est l'Unité de Recherche Génie des Réseaux de Transport et Informatique Avancée (GRE-TIA) de l'Institut National de la Recherche sur les Transports et leur Sécurité (INRETS), plus particulièrement au sein de l'équipe dite "Carrefour Intelligent" (CI). L'INRETS est un Etablissement Technique à caractère Scientifique et Technique (EPST), comme l'INRIA, multi-disciplinaire et à vocation appliquée. Les missions de l'INRETS concernent toutes les recherches et développements technologiques consacrés à l'amélioration pour la collectivité, des systèmes et moyens de transports et de circulation du point de vue technique, économique et social.

L'équipe CI est fédérée autour d'un projet, et d'un outil de recherche. Ce projet initié il y a plus de dix ans vise à modéliser le fonctionnement dynamique d'un carrefour à feux, une architecture informatique de commande de feux et de surveillance du fonctionnement d'un carrefour urbain. Le laboratoire est alimenté en temps réel par les mesures issues de plusieurs capteurs surveillant le carrefour. De nombreuses applications utilisent ces mesures. On peut citer principalement une stratégie de commande adaptative des feux, des modules de surveillance en continu du carrefour comme la détection automatique des incidents, et des modules de diagnostic multicritère évaluant l'impact des stratégies de régulation sur l'environnement et la sécurité. Peu de laboratoires dans le monde disposent de ce type d'équipement. La plupart des travaux dans le domaine et des évaluations en particulier de nouvelles méthodes se font en simulation. La force et le parti pris de ce projet est le travail dans des conditions réelles.

Le second laboratoire est le département INFormatique et RESeaux (INFRES) de l'Ecole Nationale Supérieure des Télécommunications (ENST Paris), et plus particulièrement le groupe " I3 " (Information, Interaction, Intelligence). Première institution d'enseignement supérieur à s'être consacrée essentiellement au domaine des télécommunications, l'ENST est au coeur de la dynamique des Technologies et l'Information et un acteur majeur de la recherche dans ce domaine. Les thématiques du groupe de recherche I3 tournent autour des interfaces hommes-machines, des bases de données, du traitement automatique du langage, des mondes virtuels et de l'intelligence artificielle en général. Je suis inscrit dans l'école doctorale EDITE, regroupant essentiellement les laboratoires de l'ENST et le Laboratoire d'Informatique de Paris 6 (LIP6). De plus, le Laboratoire Traitement et Communication de l'Information (LTCI), unité mixte de recherche du CNRS, regroupe tous les laboratoires de l'ENST, qui accueille dans ses équipes des chercheurs du CNRS. Ce milieu riche permet de rencontrer des chercheurs compétents dans de nombreux domaines et de connaître les derniers développements technologiques.

Ingénieur de l'ENST je suis depuis longtemps intéressé de façon générale par la recherche, et j'ai axé mon parcours dès la deuxième année sur le domaine de l'Intelligence Artificielle. Après un stage ingénieur entre la deuxième et troisième année dans un centre de recherche japonais, et ma troisième année dans le cadre de l'option Ingénierie de la cognition et de la communication homme machine, j'ai tout naturellement cherché une thèse avec une équipe spécialiste du domaine. J'ai pu m'insérer dans l'équipe de Monsieur Alain Grumbach, professeur à l'ENST, qui a été mon correspondant de stage et responsable de mémoire de troisième année. J'ai eu le choix entre une thèse financée par une bourse docteur ingénieur sur les interactions multimodales dans les mondes virtuels et la thèse financée par l'INRETS que j'ai choisie. L'aspect appliqué de ce sujet m'a tenté. J'étais aussi intéressé par une ouverture vers un autre institut de recherche que celui dans lequel je venais de passer trois ans, l'INRETS, auquel appartient ma co-directrice de thèse, Madame Sophie Midenet.

Sophie Midenet avait orienté ses travaux vers la sécurité dans les carrefours à feux depuis quelques années et voulait aborder le sujet des stratégies de régulation, d'où le

sujet de thèse. A partir de ses pistes initiales, je me suis approprié le sujet au cours de mes travaux, et l'ai orienté vers un travail personnel, en particulier pour les apports dans le domaine de l'apprentissage automatique.

C.3 Conduite du projet

C.3.1 Gestion du temps

Mes encadrants m'ont laissé très libre quant à la gestion de mon temps. Le point le plus compliqué, mais aussi très enrichissant, était ma double localisation. Il n'est pas évident de participer à la vie de deux laboratoires. Je pense cependant avoir réussi mon intégration dans ces deux équipes, et avoir eu des occasions d'échanges constructifs dans les deux équipes. J'ai en particulier présenté à différentes occasions mon travail lors de séminaires internes.

Mon sujet de thèse impliquait la réalisation d'un système opérationnel. Ceci supposait un va-et-vient constant entre le développement des modèles et des algorithmes, la manipulation des données traitées, et la validation des performances du système. J'ai donc été responsable de la gestion de mon temps et de ces itérations successives pour atteindre les objectifs de ma thèse. Si j'étais très libre dans la gestion de mon temps quotidien, je devais rendre compte régulièrement de l'avancement de mes travaux au cours de réunions régulières, espacées d'un mois à un mois et demi. A ces occasions, je devais rédiger un rapport d'avancement, capital pour évaluer le chemin parcouru, faire un bilan, expliciter des pistes, et les résultats obtenus. Au vu de ces éléments, de leur aspect pertinent et prometteur pour le sujet, nous décidions de les poursuivre ou de les abandonner. Ces rapports m'ont été d'une aide inestimable lors de la rédaction du mémoire. Nous nous sommes de plus réunis pour la rédaction de communications scientifiques. J'ai enfin consulté des chercheurs externes à ma thèse pour guider et contrôler mes avancées.

C.3.2 Gestion des relations extérieures

Je n'ai pas collaboré directement avec des partenaires extérieurs pour ma thèse. J'ai par contre noué de nombreux contacts, avec des chercheurs de mes laboratoires d'accueil pour obtenir des conseils et des avis extérieurs sur mes travaux, et en-dehors lors de conférences scientifiques. Je me suis rendu à 2 ateliers et 2 conférences avec comité de lecture, se déroulant pour moitié en France et pour l'autre moitié à l'étranger, aux Pays-Bas et en Espagne. A l'occasion de la communication de mes travaux, j'ai pu discuter avec des chercheurs des domaines du transport et de l'apprentissage automatique. Une piste pour un post-doctorat provient d'une de ces conférences. Je me suis aussi investi dans les associations de doctorants de l'INRETS et de l'ENST, ce qui m'a permis de consolider mes relations avec d'autres thésards et chercheurs. Enfin, avec deux autres doctorants de l'ENST, nous avons monté un séminaire sur l'apprentissage automatique à l'ENST, pour créer un espace de communication pour la discipline et faciliter les échanges. Ces connaissances constituent un réseau personnel que j'entretiens.

C.3.3 Budget et financement

Mon travail utilisait un laboratoire et un dispositif préexistant à ma thèse, dont se servent les deux autres chercheurs de l'équipe CI. Le seul investissement nécessaire à mon travail dans le laboratoire CI a été une licence supplémentaire du logiciel servant de plateforme de développement des applications de l'équipe. Je disposais de deux bureaux, un dans chaque laboratoire, celui de l'ENST étant partagé à 50% avec d'autres personnes, ce qui constituait le seul coût pour l'ENST (avec des consommables), qui a été par ailleurs rémunérée pour mon encadrement. Ma bourse était financée par l'INRETS, co-financée par la région Ile-de-France, pour laquelle je devais faire des rapports d'avancement annuels. Le reste des dépenses concerne du matériel et des déplacements dans des conférences, à la charge de mon unité de recherche, le GRETIA. A sa charge aussi a été un supplément de financement de 3 mois pour me permettre de terminer le projet.

Poste	Coût	Financement
Ressources humaines	91900 euros	
un doctorant (36 mois)	67000 euros	bourse INRETS co-financée à 50 % par la région Ile-de-France
allongement financement (3 mois)	5900 euros	GRETIA
Encadrement		
1 professeur (1 mois)	5000 euros	ENST
1 chargé de recherche 2 ^{ème} catégorie (2 mois)	5000 euros	INRETS
1 ingénieur de recherche (0.5 mois)	1200 euros	INRETS
Encadrement ENST (3 ans)	7800 euros	GRETIA
Matériel	16500 euros	
1 ordinateur personnel, 1 livre	1500 euros	GRETIA
1 licence du logiciel G2 sur 3 ans	15000 euros	GRETIA
Déplacements aux conférences	1900 euros	
2 jours à Amsterdam	400 euros	GRETIA
3 jours à Montpellier	400 euros	GRETIA
3 jours à Valence	850 euros	GRETIA
droits d'inscription divers	250 euros	GRETIA
Coût marginaux	19000 euros	
Locaux ENST (50%)	7500 euros	ENST
Locaux INRETS	7500 euros	INRETS
Formation au logiciel G2	3000 euros	GRETIA
Administration	1000 euros	ENST/GRETIA
TOTAL GENERAL	130 000 euros	

TABLE C.1 – Budget et financement

C.4 Compétences développées dans le cadre de mon projet

Je vais tout d'abord présenter mes compétences techniques, parmi lesquelles je distingue des connaissances ayant mis en jeu une manipulation directe des techniques, comme la programmation et le test d'algorithmes, et de la culture générale, telle qu'elle peut être acquise lors de cours, sans mise en oeuvre concrète.

Une thèse permet au premier titre de développer des connaissances techniques pointues. Ma thèse m'a donc amené à découvrir le domaine des Transports (ingénierie du transport, sécurité dans les transports, systèmes de transport intelligents), et à approfondir mes connaissances en Intelligence Artificielle et Apprentissage Automatique (méthodes incrémentales, combinaison de modèles). J'avais déjà eu l'occasion de travailler sur des sujets connexes, l'apprentissage par renforcement en stage ingénieur, les interfaces hommes machines et les mondes virtuels dans le cadre de mon mémoire de troisième année à l'ENST. Enfin, les cours de l'ENST m'ont donné une culture générale dans le traitement du signal et de l'image, la fusion de données et d'autres domaines liés à l'intelligence artificielle comme le traitement du langage naturel, les systèmes experts et les sciences cognitives

Ma thèse a été également une période de formation et d'apprentissage de nouvelles méthodes de travail, avec la conduite d'un projet de recherche grandeur réelle. Elle a été l'occasion pour moi de mettre en oeuvre et développer des compétences techniques dans un cadre appliqué concret. J'y ai trouvé un bon équilibre entre la recherche de techniques innovantes et la réalisation de systèmes qui fonctionnent, mission de l'ingénieur. La réussite de ce projet a mis à contribution ma capacité d'analyse et de synthèse, nécessaires en particulier à la réalisation de rapports scientifiques, d'articles scientifiques soumis à des conférences, et du mémoire de thèse. La recherche implique de communiquer avec ses pairs, et j'ai donc présenté mon travail à de nombreuses occasions, dans des séminaires internes, des ateliers et des conférences, nationaux et internationaux, impliquant la maîtrise de l'anglais. La conduite de ce projet a mis en évidence mes capacités d'autonomie, de rigueur, d'adaptabilité (double localisation), de communication, de créativité et de tenacité.

J'ai eu d'autre part l'occasion de prendre part à des expériences d'enseignement variées. J'ai encadré des travaux pratiques en algorithmique, intelligence artificielle et différents langages de programmation. J'ai eu recours à des projets d'élèves pour développer des pistes alternatives à mes travaux dans le cadre de ma thèse. J'ai enfin complètement réalisé le cours d'introduction au langage Java, les travaux pratiques et l'examen correspondant du master ouvert en 2003 par l'ENST pour des étudiants étrangers. J'ai apprécié le contact avec les élèves et la nécessité d'expliquer et clarifier mes travaux pour collaborer avec d'autres personnes.

C.5 Conclusion

L'impact principal de ma thèse consiste en l'ouverture de nouvelles pistes de recherche dans le domaine de la sécurité dans les transports. Mon outil de diagnostic a été testé pour comparer l'impact de stratégies de gestion des feux de signalisation sur la sécurité et le comportement des usagers, travail inédit à ce jour. Le perfectionnement des techniques utilisées, des capteurs et des méthodes de traitement d'images sous-jacents, nous permettent d'envisager à terme une nouvelle famille d'outils de diagnostic de la sécurité en temps réel, permettant l'évaluation d'un lieu en quelques jours, quand le temps nécessaire à des analyses comparables s'appuyant sur les accidents se compte en années.

Je compte dans un premier temps continuer la recherche dans le domaine de la sécurité dans les transports et de nouveaux outils de diagnostic, tout en découvrant de nouvelles cultures et méthodes de travail. Pour cela, j'ai cherché un "post-doctorat" à l'étranger dès l'été 2004. J'ai contacté un chercheur rencontré lors de ma participation à la conférence internationale aux Pays-bas, qui travaille à l'Université de Colombie Britannique de Vancouver et les contacts doivent aboutir prochainement.

La conduite de ma thèse constitue un enjeu social très fort et me permet de valider une expérience professionnelle à part entière. Je retire la satisfaction d'avoir mené un projet ambitieux m'ayant permis d'acquérir de nombreuses compétences et qualités indispensables à mon insertion professionnelle. La conduite de projet inclut de nombreuses qualités, telles que l'adaptation au travail en équipe, la maîtrise de l'anglais, l'esprit d'analyse, des capacités d'organisation et de communication, l'autonomie dans le travail.

Bibliographie

- ABE, N. et MAMITSUKA, H. (1998). Query learning strategies using boosting and bagging. *In Proceedings of the Fifteenth International Conference on Machine Learning*.
- ALMQVIST, S. et HYDÉN, C. (1994). Methods for assessing traffic safety in developing countries. *Building issues*, 6(1).
- AMUNDSEN, F. et HYDÉN, C., éditeurs (1977). *Proceedings of the first workshop on traffic conflicts*, Oslo, Norway. Institute of Transport Economics.
- ANDERSSON, J. (2000). A new traffic analysis method based on image processing. Bulletin 193, University of Lund.
- ANONYME (1988). *Carrefours à feux*. CETUR, Ministère du logement, de l'équipement, de l'aménagement du territoire et des transports.
- ANONYME (1996). *Instruction interministérielle sur la signalisation routière, Livre I. Sixième Partie, Feux de circulation permanents*. CETUR, SETRA, Ministère du logement, de l'équipement, de l'aménagement du territoire et des transports and Ministère de l'intérieur. Brochure numéro 5352.
- ANONYMOUS (1991). Afnor, régulation du trafic routier, feux de circulation, terminologie.
- ANONYMOUS (1996). *Expected value conflict tables for Florida-based traffic crashes*. Center for Urban Transportation Research.
- ANONYMOUS (2005). The swedish traffic conflict technique. WWW.
- ANTOV, D. (1990). State of the art of the use of traffic conflicts techniques and other pre-accident criteria in the soviet union especially in the baltic republics. *In DRASKÓCZY, M., éditeur : Proceedings of the third workshop of ICTCT*, pages 2–6, Cracow. ICTCT.
- ARON, M., SEDDIKI, E. et chow WAH, L. H. (1994). Using individual measurements of traffic on motorways. pages 56–63, Paris. ATT/IVHS.
- ATLAS, L., COHN, D. et LADNER, R. (1990). Training connectionist networks with queries and selective sampling. *In TOURETZKY, D., éditeur : Advances in Neural Information Processing Systems 2*, San Mateo. Morgan Kaufmann.
- BAKER, J. et ROSS, H. L. (1961). Concepts and classification of traffic accident causes (Part 1). *International Road Safety and Traffic Review*, 9(31):11–18.
- BARAM, Y., EL-YANIV, R. et LUZ, K. (2004). Online choice of active learning algorithms. *Journal on Machine Learning Research*, 5:255–291.

- BECK, U. (1986). *La Société du risque : Sur la voie d'une autre modernité*. Champs. Flammarion.
- BLAKE, C. et MERZ, C. (1998). UCI repository of machine learning databases.
- BLUM, A. (1998). *Online Algorithms : the state of the art*, chapitre On-Line Algorithms in Machine Learning (a survey). Numéro 1442 de LNCS. Fiat and Woeginger.
- BLUM, A. et MITCHELL, T. (1998). Combining labeled and unlabeled data with co-training. *In Proceedings of the 11th Annual Conference on Computational Learning Theory*, pages 92–100.
- BOILLOT, F. (2002a). Carrefour intelligent, la gestion des carrefours à feux. Fiche de présentation GRETIA.
- BOILLOT, F. (2002b). Cronos, un algorithme de régulation du trafic urbain en temps réel. Fiche de présentation GRETIA.
- BOILLOT, F., BLOSSEVILLE, J., LESORT, J., MOTYKA, V., PAPAGEORGIOU, M. et SELLAM, S. (1992). Optimal signal control of urban traffic networks. *In Sixth International Conference on Road Traffic Monitoring and Control*, numéro 355, pages 75–79, London. IEE.
- BOILLOT, F., MIDENET, S. et PIERRELÉE, J.-C. (2000). Real-life cronos evaluation. *In Tenth International Conference on Road Traffic Information and Control*, numéro 472, pages 182–186, London. IEE.
- BOUCHON-MEUNIER, B. (1994). *La logique floue*. Que sais-je ? Presses Universitaires de France.
- BRABAN, C. et BOILLOT, F. (2003). *Les systèmes adaptatifs de régulation du trafic en milieu urbain, Synthèse INRETS n°44*. INRETS.
- BREDECHE, N., ZUCKER, J.-D. et ZHONGZHI, Z. (2003). Online learning for object identification by a mobile robot. *In Proceedings of the 5th IEEE International Symposium on Computational Intelligence in Robotics and Automation (CIRA2003)*, volume 2, pages 630–635.
- BREIMAN, L. (1996). Bagging predictors. *Machine Learning*, 24(2):123–140.
- BROWN, G. R. (1991). *Near-miss reporting as a safety tool*, chapitre Chapter 10 : Use of traffic conflicts for near-miss reporting, pages 111–125. Butterworth-heinemann, Oxford, England.
- BROWN, G. R. (1994). Traffic conflict for road user safety studies. *Canadian Journal of Civil Engineering*, 21:1–15.
- CESA-BIANCHI, N., CONCONI, A. et GENTILE, C. (2003). Learning probabilistic linear-threshold classifiers via selective sampling. *Lecture Notes in Computer Science*, 2777: 373–387.
- CESA-BIANCHI, N., GENTILE, C. et ZANIBONI, L. (2004). Worst-case analysis of selective sampling for linear-threshold algorithms. *In Advances in Neural Information Processing Systems 17*, Vancouver. MIT Press.

- COHEN, S. (1993). *Ingénierie du Trafic Routier. Eléments de Théorie du Trafic et Applications*. Presses Ponts et Chaussées.
- COHEN, W. W., SCHAPIRE, R. E. et SINGER, Y. (1999). Learning to order things. *Journal of Artificial Intelligence Research*, 10:243–270.
- COHN, D., ATLAS, L. et LADNER, R. E. (1994). Improving generalization with active learning. *Machine Learning*, 15(2):201–221.
- COHN, D. A., GHAHRAMANI, Z. et JORDAN, M. I. (1995). Active learning with statistical models. In TESAURO, G., TOURETZKY, D. et LEEN, T., éditeurs : *Advances in Neural Information Processing Systems*, volume 7, pages 705–712. The MIT Press.
- COOPER, D. et FERGUSON, N. (1976). Traffic studies at t-junctions, a conflict simulation model. *Traffic Engineering and Control*, 17:306–309.
- CORNUÉJOLS, A., MICLET, L. et KODRATOFF, Y. (2002). *Apprentissage Artificiel*. Eyrolles.
- DAGAN, I. et ENGELSON, S. P. (1995). Committee-based sampling for training probabilistic classifiers. In *Proceedings of the 12th International Conference on Machine Learning (ML-95)*, pages 150–157.
- de LEUR, P. et SAYED, T. (2002). Development of a road safety risk index. *Transportation Research Record : Journal of the Transportation Research Board*, 1784:33–42.
- DESROCHES, A., LEROY, A. et VALLÉE, F. (2003). *La gestion des risques, principes et pratiques*. Lavoisier.
- DIETTERICH, T. G. (1998). Machine-learning research : Four current directions. *The AI Magazine*, 18(4):97–136.
- DIETTERICH, T. G. (2000). An experimental comparison of three methods for constructing ensembles of decision trees : Bagging, boosting, and randomization. *Machine Learning*, 40(2):139–158.
- DIETTERICH, T. G. (2002). *The Handbook of Brain Theory and Neural Networks, Second edition*, chapitre Ensemble Learning, pages 405–408. The MIT Press, Cambridge, MA.
- DIEZ, J., del COZ, J., LUACES, O., GOYACHE, F., ALONSO, J., PEÑA, A. M. et BAHAMONDE, A. (2002). Learning to assess from pair-wise comparisons. In *Proceedings of the 8th Iberoamerican Conference on Artificial Intelligence (IBERAMIA)*, numéro 2527 de LNAI, pages 481–490, Sevilla, Spain.
- DOMINGOS, P. et HULTEN, G. (2000). Mining high-speed data streams. In *Knowledge Discovery and Data Mining*, pages 71–80.
- DOMINGOS, P. et PAZZANI, M. (1997). On the optimality of the simple bayesian classifier under zero-one loss. *Machine Learning*, 29:103–130.
- DUDA, R. O. et HART, P. E. (2000). *Pattern Classification*. Wiley-Interscience.
- EKMAN, L. (1995). Safety performance functions - tools for improved use of safety and exposure data. In *8th ICTCT Workshop*, pages 38–41, Paris. ICTCT.

- FLEURY, D. (1993). Statistical and in-depth analysis of accidents, report - working group d. In *6th ICTCT workshop*, pages 1–4, Salzburg. ICTCT.
- FLEURY, D. et BRENAC, T. (2001). Accident prototypical scenarios, a tool for road safety research and diagnostic studies. *Accident Analysis & Prevention*, 2(33):267–276.
- FONTAINE, H. (2004). Risque routier. Projet R.E.C.I.T.S.
- FRANK, E. et HALL, M. (2001). A simple approach to ordinal classification. Working paper, Department of Computer Science, University of Waikato.
- FREUND, Y. (1995). Boosting a weak learning algorithm by majority. *Information and Computation*, 121(2):256–285.
- FREUND, Y., SEUNG, H. S., SHAMIR, E. et TISHBY, N. (1997). Selective sampling using the query by committee algorithm. *Machine Learning*, 28(2-3):133–168.
- FÜRNKRANZ, J. (1998). Integrative windowing. *Journal of Artificial Intelligence Research*, 8:129–164.
- FÜRNKRANZ, J. et HÜLLERMEIER, E. (2005). Preference learning. *Künstliche Intelligenz*, 19(1):60–61.
- GÅRDER, P. (1989). Pedestrian safety at traffic signals : a study carried out with the help of a traffic conflicts technique. *Accident Analysis & Prevention*, 21(5):435–444.
- GETTMAN, D. et HEAD, L. (2003). Surrogate safety measures from traffic simulation models, final report. Rapport technique FHWA-RD-03-050, Federal Highway Administration.
- GEURTS, P. (2003). Extremely randomized trees. Rapport technique, University of Liège.
- GHANI, R. (2002). Combining labeled and unlabeled data for multiclass text categorization. In *International Conference on Machine Learning (ICML 2002)*, Sydney, Australia.
- GHANI, R. et ROSENBERG, R. J. C., éditeurs (2003). *Proceedings of the ICML-2003 Workshop : The Continuum from Labeled to Unlabeled Data in Machine Learning & Data Mining*, Washington DC.
- GOURLET, Y. (2004). Le fichier baac. Projet R.E.C.I.T.S.
- GUEDES, E. P., BRAGA, M. et PIETRANTONIO, H. (1997). Initial experience with traffic conflict techniques in brazil. In *ICTCT 97 Conference*, pages 1–11, Lund. ICTCT.
- HAIGHT, F. A. (1986). Risk, especially risk of traffic accident. *Accident Analysis & Prevention*, 18(5):359–366.
- HAKKERT, A. et BRAIMAISTER, L. (2002). The uses of exposure and risk in road safety studies. Rapport technique R-2002-12, SWOV, Leidschendam.
- HAUER, E. (1980). Bias-by-selection : overestimation of the effectiveness of safety countermeasures caused by the process of selection for treatment. *Accident Analysis & Prevention*, 12(2):113–117.
- HAUER, E. (1995). On exposure and accident rate. *Traffic Engineering + Control*, 36(3):134–138.

- HAUER, E. (2001). Computing and interpreting accident rates for vehicle types or driver groups. *Transportation Research Record : Journal of the Transportation Research Board*, 1746(1746):69–73.
- HAUER, E., HARWOOD, D. W. et COUNCIL, F. M. (2002). The empirical bayes method for estimating safety : A tutorial. *Transportation Research Record : Journal of the Transportation Research Board*, 1784:126–131. National Academies Press, Washington, D.C.
- HAUER, E., NG, J. et LOVELL, J. (1988). Estimation of safety at signalized intersections. *Transportation Research Record : Journal of the Transportation Research Board*, 1185:48–61.
- HO, S.-S. et WECHSLER, H. (2004). Learning from data streams via online transduction. In (Ma *et al.*, 2004), pages 45–52.
- HOLMES, G., KIRKBY, R. et PFAHRINGER, B. (2004). Mining data streams using option trees (revised edition, 2004). Rapport technique, Department of Computer Science, The University of Waikato, Hamilton.
- HYDÉN, C. (1987). *The development of a method for traffic safety evaluation : The Swedish Traffic Conflicts Technique*. Thèse de doctorat, Lund University of Technology, Lund, Sweden. Bulletin 70.
- HYDÉN, C. et VÁRHELYI, A. (2000). The effects of safety, time consumption and environment of large scale use of roundabouts in an urban area : a case study. *Accident Analysis & Prevention*, 32:11–23.
- IYENGAR, V. S., APTE, C. et ZHANG, T. (2000). Active learning using adaptive resampling. In *Sixth ACM SIGKDD Intl. Conf. on Knowledge Discovery and Data Mining*, pages 92–98.
- JACQUEMART, G. (1998). Synthesis of highway practice 264 :modern roundabout practice in the united states. Rapport technique, National Cooperative Highway Research Program, Washington, D.C. National Academy Press.
- JIN, R. et GHAMRANI, Z. (2003). Learning with multiple labels. In BECKER, S., THRUN, S. et OBERMAYER, K., éditeurs : *Advances in Neural Information Processing Systems 15*, pages 897–904. MIT Press, Cambridge, MA.
- JOHN, G. H. et LANGLEY, P. (1995). Estimating continuous distributions in bayesian classifiers. In *Proceedings of the Eleventh Conference on Uncertainty in Artificial Intelligence*, pages 338–345, San Mateo. Morgan Kaufmann.
- KALAI, A. et VEMPALA, S. (2003). Efficient algorithms for online decision problems. In *Proceedings of the 16th Annual Conference on Computational Learning Theory*.
- KATAMINE, N. M. et HAMARNEH, I. M. (1998). Use of the traffic conflict technique to identify hazardous intersections. *Road & Transport Research*, 7(3):17–35.
- KERDPRASOP, N. et KERDPRASOP, K. (2003). Data partitioning for incremental data mining. In *The 1st International Forum on Information and Computer Science*, pages 114–118, Shizuoka University, Japan.

- KRUYSSSE, H. W. (1991). The subjective evaluation of traffic conflicts based on an internal concept of dangerousness. *Accident Analysis & Prevention*, 23(1):53–65.
- KULKARNI, S., LUGOSI, G. et VENKATESH, S. (1999). *Information Theory : 50 Years of Discovery*, chapitre Learning Pattern Classification - A Survey. IEEE Press, New York.
- KULMALA, R. (1995). Unused source of information. In *8th ICTCT Workshop*, pages 33–37, Paris. ICTCT.
- LE CERF, V. (1999). *Suivi symbolique de véhicules dans un carrefour urbain à partir de plusieurs caméras*. Thèse de doctorat, Université de Paris 6.
- LEE, H. K. H. et CLYDE, M. A. (2004). Lossless online bayesian bagging. *Journal on Machine Learning Research*, 5:143–151.
- LEWIS, D. D. et CATLETT, J. (1994). Heterogeneous uncertainty sampling for supervised learning. In COHEN, W. W. et HIRSH, H., éditeurs : *Proceedings of ICML-94, 11th International Conference on Machine Learning*, pages 148–156, New Brunswick, US. Morgan Kaufmann Publishers, San Francisco, US.
- LEWIS, D. D. et GALE, W. A. (1994). A sequential algorithm for training text classifiers. In *Proceedings of the 17th annual international ACM SIGIR conference on Research and development in information retrieval*, pages 3–12. Springer-Verlag New York, Inc.
- LIERE, R. et TADEPALLI, P. (1997). Active learning with committees for text categorization. In *Proceedings of AAAI-97*, Providence.
- LINDENBAUM, M., MARKOVITCH, S. et RUSAKOV, D. (1999). Selective sampling for nearest neighbor classifiers. In *AAAI/IAAI*, pages 366–371.
- LITTLESTONE, N. (1988). Learning quickly when irrelevant attributes are abound : A new linear threshold algorithm. *Machine Learning*, 2:285–318.
- LITTLESTONE, N. et WARMUTH, M. (1994). The weighted majority algorithm. *Information and Computation*, 2(104):212–261.
- MA, S., LI, T. et PERNG, C.-S., éditeurs (2004). *Workshop Proceedings, Temporal Data Mining : Algorithms, Theory and Applications*, Brighton. ICDM 2004.
- MAHALEL, D., ZAIDEL, D. et KLEIN, T. (1985). Driver's decision process on termination of the green light. *Accident Analysis & Prevention*, 17(5):373–380.
- MCCALLUM, A. K. et NIGAM, K. (1998). Employing EM in pool-based active learning for text classification. In SHAVLIK, J. W., éditeur : *Proceedings of ICML-98, 15th International Conference on Machine Learning*, pages 350–358, Madison, US. Morgan Kaufmann Publishers, San Francisco, US.
- MELVILLE, P. et MOONEY, R. (2003). Constructing diverse classifier ensembles using artificial training examples. In *Proceedings of the Eighteenth International Joint Conference on Artificial Intelligence*, pages 505–510, Mexico.
- MELVILLE, P. et MOONEY, R. (2004). Diverse ensembles for active learning. In *Proceedings of the 21st International Conference on Machine Learning (ICML-2004)*, pages 584–591, Banff, Canada.

- MIDENET, S. (1998). Cartes auto-organisatrices pour l'interprétation de mesures spatiales et la description du trafic au centre de carrefours. *In Session Transport du congrès "Systèmes complexes, systèmes intelligents et interfaces" Nîmes 98*, volume 134-135-136, pages 240–244, Nîmes. La lettre de l'IA.
- MIDENET, S. (2002). Audit multi-critère du fonctionnement d'un carrefour à feux. Fiche de présentation GRETIA.
- MIDENET, S., BOILLOT, F. et PIERRELÉE, J.-C. (2004). Signalized intersection with real-time adaptative control : on-field assessment of CO₂ and pollutant emission reduction. *Transportation Research Part D*, 9:29–47.
- MIDENET, S., BOILLOT, F. et PIERRELÉE, J.-C. (1999). Evaluation des enjeux énergétiques et environnementaux liés à la gestion des incidents dans les carrefours à feux isolés. Rapport technique Convention ADEME 4030038, INRETS.
- MIDENET, S., BOILLOT, F. et PIERRELÉE, J.-C. (2000). Enjeux de la régulation aux carrefours pour réduire la consommation et la pollution. *In 9^{ème} Colloque Scientifique International Transports et Pollution de l'air*, numéro 70, pages 547–552, Avignon. Actes INRETS.
- MIGLEZ, D. J., GLAUZ, W. D. et BAUER, K. M. (1985). Relationships between traffic conflicts and accidents. Rapport technique FHWA/RD-84/042, Federal Highway Administration, Virginia, USA.
- MINDERHOUD, M. M. et BOVY, P. H. (2001). Extended time-to-collision measures for road traffic safety assessment. *Accident Analysis & Prevention*, 33(1):89–97.
- MUHLRAD, N. (1988). *Technique des Conflits de Trafic, Manuel de l'utilisateur, Synthèse INRETS n°11*. INRETS.
- MUHLRAD, N. (1993). Traffic conflict technique and other forms of behavioural analysis : Application to safety diagnosis. *In 6th ICTCT workshop*, pages 48–64, Salzburg. ICTCT.
- MUSLEA, I., MINTON, S. et KNOBLOCK, C. (2000). Selective sampling with redundant views. *In Proceedings of the Fifteenth National Conference on Artificial Intelligence*, pages 621–626. AAAI.
- NOYCE, D. A., FAMBRO, D. B. et KACIR, K. C. (2000). Traffic conflicts associated with protected/permitted left-turn signal displays. *In 79th Annual Meeting of the Transportation Research Board*, Washington, D.C.
- NYGARD, M. (1999). A method for analysing traffic safety with the help of speed profiles. Mémoire de D.E.A., Tampere University of Technology.
- ODELID, K. et SVENSSON, A. (1993). A more automatic conflict technique with image processing. *In 6th ICTCT Workshop*, pages 285–290, Salzburg. ICTCT.
- OPPE, S. (1993). Possibilities and limitations of accident analysis. *In 6th ICTCT workshop*, pages 32–47, Salzburg. ICTCT.

- OZA, N. et RUSSELL, S. (2001). Online bagging and boosting. *In Eighth International Workshop on Artificial Intelligence and Statistics*, pages 105–112, Key West, Florida. Morgan Kaufmann.
- PARKER, M. R. et ZEGER, C. V. (1989). Traffic conflict techniques for safety and operations, observers manual. Rapport technique FHWA-IP-88-027, Federal Highway Administration.
- PERKINS, S. R. et HARRIS, J. I. (1968). Traffic conflicts characteristics : Accident potential at intersections. *Highway Research Record*, 225:35–43. Highway Research Board, Washington D.C.
- POLIKAR, R., UDPA, L., UDPA, S. S. et HONAVAR, V. (2001). Learn++ : An incremental learning algorithm for supervised neural networks. *IEEE Transactions on Systems, Man, and Cybernetics Part C : Applications and Reviews*, 31(4):497–508.
- RALAIVOLA, L. et d'Alché BUC, F. (2001). Apprentissage incrémental pour les svm : une approche locale. *In Actes de la Conférence Apprentissage CAp*, Grenoble.
- REICHARDT, R. H., éditeur (1992). *Proceedings of the 4th workshop of ICTCT*, Bulletin 110, Vienna. ICTCT, University of Lund, Department of Traffic Planning and Engineering.
- RETTING, R. R., CHAPLINE, J. F. et WILLIAMS, A. F. (2002). Changes in crash risk following re-timing of traffic signal change intervals. *Accident Analysis & Prevention*, 34(2):215–220.
- RICK, A. (2001). *Représentation de la variabilité dans le traitement d'images flou, Application à la mammographie numérique*. Thèse de doctorat, Université Paris 6.
- ROBINSON, B., RODEGERDTS, L., SCARBOROUGH, W., KITTELSON, W., TROUTBECK, R., BRILON, W., BONDZIO, L., COURAGE, K., KYTE, M., MASON, J., FLANNERY, A., MYERS, E., BUNKERS, J. et JACQUEMART, G. (2000). Roundabouts : An informational guide. Rapport technique FHWA-RD-00-068, Federal Highway Administration.
- ROOK, A. (2003). The first glimpse at an integrated approach of accident analysis. *In 16th International Cooperation on Theories and Concepts in Traffic Safety Workshop*, Soesterberg, Holland.
- ROY, N. et MCCALLUM, A. (2001). Toward optimal active learning through sampling estimation of error reduction. *In Proc. 18th International Conf. on Machine Learning*, pages 441–448. Morgan Kaufmann, San Francisco, CA.
- RUSSAM, K. et SABEY, B. (1972). Accidents and traffic conflicts at junctions. Rapport technique LR 514, Transport and Road Research Laboratory.
- SAAD, F. et DIONISIO, C. (1999). Erreurs, infraction et prises de risques des conducteurs en situation réelle de conduite. Rapport sur convention, INRETS DRAST.
- SAAR-TSECHANSKY, M. et PROVOST, F. (2004). Active sampling for class probability estimation and ranking. *Machine Learning*, 54(2):153–178.

- SAUNIER, N., MIDENET, S. et GRUMBACH, A. (2003). Automatic detection of vehicle interactions in a signalized intersection. In *16th International Cooperation on Theories and Concepts in Traffic Safety Workshop*, Soesterberg, The Netherlands.
- SAUNIER, N., MIDENET, S. et GRUMBACH, A. (2004a). Apprentissage incrémental par sélection de données dans un flux pour une application de sécurité routière. In LIQUIÈRE, M. et SEBBAN, M., éditeurs : *Conférence d'Apprentissage*, pages 239–251, Montpellier. PUG.
- SAUNIER, N., MIDENET, S. et GRUMBACH, A. (2004b). Coopération entre système d'inférence et système de reconnaissance ; détection de situations dangereuses dans un carrefour à feux. *Génie Logiciel*, 71:20–24.
- SAUNIER, N., MIDENET, S. et GRUMBACH, A. (2004c). Stream-based Learning through Data Selection in a Road Safety Application. In ONAINDIA, E. et STAAB, S., éditeurs : *STAIRS 2004, Proceedings of the Second Starting AI Researchers' Symposium*, volume 109 de *Frontiers in Artificial Intelligence and Applications*, pages 107–117, Valencia, Spain. IOS Press.
- SAYED, T. (1997). Estimating the safety of unsignalized intersections using traffic conflicts. In *Proceedings of the Third International Symposium on Intersections Without Traffic Signals*, pages 230–235, Portland, OR. Washington (DC) : Transportation Research Board.
- SAYED, T., ABDELWAHAB, W. et NAVIN, F. (1995). Identifying accident-prone locations using fuzzy pattern recognition. *Journal of Transportation Engineering*, 121(4):352–358.
- SAYED, T., BROWN, G. R. et NAVIN, F. (1994). Simulation of Traffic Conflicts at Unsignalized Intersections with TSC-Sim. *Accident Analysis & Prevention*, 26(5):593–607.
- SAYED, T. et ZEIN, S. (1999). Traffic conflict standards for intersections. *Transportation Planning and Technology*, 22:309–323.
- SCEMAMA, G. (2002). Claire++, un système indépendant de supervision de la congestion du trafic routier. Fiche de présentation GRETIA.
- SCHAPIRE, R. E. (1990). The strength of weak learnability. *Machine Learning*, 5(2):197–227.
- SCHAPIRE, R. E., FREUND, Y., BARTLETT, P. et LEE, W. S. (1997). Boosting the margin : a new explanation for the effectiveness of voting methods. In *Proc. 14th International Conference on Machine Learning*, pages 322–330. Morgan Kaufmann.
- SCHOHN, G. et COHN, D. (2000). Less is more : Active learning with support vector machines. In *Proc. 17th International Conf. on Machine Learning*, pages 839–846. Morgan Kaufmann, San Francisco, CA.
- SEDDIKI, E., ARON, M. et FABRE, P. (1999). Intérêt des indicateurs de comportement des conducteurs pour la mesure de l'impact des pmv : le cas de l'autoroute a31. In *Sécurité et sûreté dans les déplacements*, pages 23–33, Paris. ATEC, Presses de l'école nationales des Ponts et chaussées.

- SEEGER, M. (2000). Learning with labeled and unlabeled data. Rapport technique, Institute for ANC, Edinburgh, UK.
- SEEWALD, A. K. (2003). Towards a theoretical framework for ensemble classification. *In Proceedings of the Eighteenth International Joint Conference on Artificial Intelligence (IJCAI-03)*, pages 1443–1444. Morgan Kaufmann.
- SEUNG, H. S., OPPER, M. et SOMPOLINSKY, H. (1992). Query by committee. *In Computational Learning Theory*, pages 287–294.
- SPENLEHAUER, V. et LASSARRE, S. (2003). La recherche pour l'insécurité. *Pour la Science*, 309:72–76.
- SUTTON, R. S. et WHITEHEAD, S. D. (1993). Online Learning with Random Representations. *In Machine Learning : Proceedings of the Tenth International Conference*, pages 314–321, San Mateo, CA. Morgan Kaufmann.
- SVENSSON, A. (1998). *A Method for Analyzing the Traffic Process in a Safety Perspective*. Thèse de doctorat, University of Lund. Bulletin 166.
- TONG, S. (2001). *Active Learning : Theory and Applications*. Thèse de doctorat, Department of Computer Science of Stanford University.
- TORRE, F. (2004). Globoost : Boosting de moindres généralisés. *In LIQUIÈRE, M. et SEBBAN, M., éditeurs : Actes de la Sixième Conférence Apprentissage CAp'2004*, pages 49–64. PUG.
- UTGOFF, P. E. (1989). Incremental induction of decision trees. *Machine Learning*, 4:161–186.
- UTGOFF, P. E., BERKMAN, N. C. et CLOUSE, J. A. (1997). Decision tree induction based on efficient tree restructuring. *Machine Learning*, 29(1):5–44.
- van der HORST, R. (1988). Driver decision making at traffic signals. *Transportation Research Record : Journal of the Transportation Research Board*, 1172:93–97.
- van der HORST, R. (1990). *A time-based analysis of road user behavior in normal and critical encounter*. Thèse de doctorat, Delft University of Technology.
- van der HORST, R. et WILMINK, A. (1986). Drivers' decision-making at signalized intersections : an optimization of the yellow timing. *Traffic Engineering Control*, 27:615–622.
- VAPNIK, V. (1998). *Statistical Learning Theory*. Wiley-InterScience.
- VEERARAGHAVAN, H., MASOUD, O. et PAPANIKOLOPOULOS, N. P. (2002). Managing suburban intersections through sensing. Rapport technique CTS 02-07, University of Minnesota, Minneapolis.
- VINOT, R. (2004). *Classification automatique de textes dans des catégories non thématiques*. Informatique et réseaux, Télécom Paris (ENST).
- VOGEL, K. (2003). A comparison of headway and time to collision as safety indicators. *Accident Analysis & Prevention*, 35(3):427–433.

- WAKABAYASHI, H. et RENGE, K. (2000). Traffic conflict analysis using vehicle tracking system with digital vcr and new conflict indicator under high speed and congested traffic environment. *In Proceedings of the 19th Dresden Conference on Traffic and Transportation Sciences, "Mobility and Traffic Management in a Networked World"*, Dresden. CD-ROM.
- WEBB, G., BOUGHTON, J. et WANG, Z. (2005). Not so naive bayes : Aggregating one-dependence estimators. *Machine Learning*, 58:1–20.
- WITTEN, I. H. et FRANK, E. (2000). *Data Mining : Practical machine learning tools with Java implementations*. Morgan Kaufmann, San Francisco.
- WORTMAN, R. H., WITKOWSKI, J. M. et FOX, T. C. (1985). Traffic characteristics during signal change intervals. *Transportation Research Record : Journal of the Transportation Research Board*, 1027:4–6. Transportation Research Board, National Research Council, Washington, DC.
- YAN, R., YANG, J. et HAUPTMANN, A. (2003). Automatically labelling video data using multi-class active learning. *In Proceedings. Ninth IEEE International Conference on Computer Vision, 2003*, pages 516–523.

Index

- accident potentiel, 12
- AdaBoost, 101
- algorithme anytime, 87
- algorithme incrémental, 86
- algorithme incrémental lossless, 87
- algorithme instable, 99
- analyse dans le pire des cas, 79
- analyse en cas moyen, 79
- apprenant, 76
- apprenant actif, 91
- apprentissage actif, 91
- apprentissage actif dans un flux continu de données, 93
- apprentissage actif dans un réservoir de données, 93
- apprentissage artificiel, 74
- apprentissage guidé, 74
- apprentissage incrémental avec nombre d'erreurs, 89
- apprentissage incrémental avec perte relative, 89
- Bagging, 101
- biais inductif, 78
- Boosting, 101
- cadre en ligne, 86
- cadre sélectif, 91
- cadre séquentiel, 86
- carrefour, 7
- carrefours à feux, 7
- catégorie amont, 34
- catégorie amont seul, 34
- catégorie antagoniste, 35
- catégorie aval, 34
- catégories d'interaction, 33
- classifieur bayésien naïf, 106
- coût, 76
- comité d'hypothèses, 100
- compromis biais-variance, 78
- conflit de trafic, 21
- contexte d'une interaction, 49
- courants, 7
- CRONOS, 10
- cycle, 7
- dilemme stabilité-plasticité, 87
- distribution des expositions, 51
- distribution des pourcentages d'exposition, 51
- donnée, 76
- données mal-classées, 97
- échelle de sévérité, 13
- ensemble d'apprentissage, 81
- ensemble d'hypothèses, 100
- ensemble de test, 81
- ensemble de validation, 81
- environnement, 6, 76
- erreur d'approximation, 78
- erreur d'estimation, 78
- espace de représentation des objets, 76
- espace de supervision, 76
- espace des versions, 94
- étiquette, 76
- exemple, 76
- expert, 76
- exposition, 17, 51
- facteur d'accident, 19
- feux de circulation, 7
- feux tricolores, 7
- flux de données, 86
- fonction de performance en sécurité, 17

- forme, 58
- G2, 157
- gêne, 15
- gravité, 11
- hiérarchie de sécurité, 11
- hypothèse de base, 100
- hypothèse probabiliste, 95
- hypothèses d'extrapolation, 32
- imprécision, 84
- incertitude, 84
- indicateur de proximité, 45, 63
- indicateur de vitesse, 45, 82
- indicateurs de sévérité, 45
- induction, 76
- interaction, 11
- interaction critique, 12
- Java, 163
- méthode de combinaison d'hypothèses, 100
- méthode de régulation, 7
- macro-régulation, 9
- manœuvre d'évitement, 12
- marge de manœuvre, 14
- matrice de confusion, 66
- MC, 97
- micro-régulation, 9
- mobile, 6
- mobile impliqué, 11
- mobile protagoniste, 11
- mouvement, 7
- niveau de description des données, 39
- obstacle, 6
- oracle, 76
- pavé, 39
- perte, 76
- PET, 22
- phase, 7
- plan de feux, 7
- point conflictuel, 7
- point de collision potentielle, 12
- point noir, 19
- post-encroachment time, 22
- précision, 67
- primitives de mouvement, 60
- principe de compression d'information, 79
- principe de décision bayésienne, 78, 106
- principe de minimisation du risque empirique, 78
- principe inductif, 77
- programmation horaire, 9
- pyramide de sécurité, 12
- quasi-accident, 12
- réponse désirée, 76
- rappel, 67
- regret, 89
- requêtes d'appartenance, 91
- risque, 14
- risque subjectif, 14
- sévérité, 13
- signaux tricolores, 7
- stratégie adaptative, 10
- stratégie de régulation, 7
- stratégie temps réel, 10
- superviseur, 76
- surapprentissage, 80
- systèmes à base de règles, 56
- systèmes experts, 56
- tâche d'apprentissage, 76
- TA, 22
- technique des conflits de trafic, 21
- temps à la collision, 22
- temps post-empiètement, 22
- time to accident, 22
- time to collision, 22
- trajectoire de collision, 12
- transfert de connaissance, 74

TTC, 22

usagers, 6

usagers vulnérables, 6

véhicules, 6

validation croisée, 81

variance, 78

vote, 100

Vote AleaMC, 105

Vote MC, 104

Weka, 163

Windowing, 97

zone de conflit, 7

zones fonctionnelles, 7